



# Demir Tenör Değerlerinin Kestiriminde Makine Öğrenme Yöntemlerinin Karşılaştırılması

## Comparison of Machine Learning Methods in Estimation of Iron Grade Values

Fırat ATALAY<sup>1\*</sup>

<sup>1</sup> Hacettepe Üniversitesi, Maden Mühendisliği Bölümü, [atalay@hacettepe.edu.tr](mailto:atalay@hacettepe.edu.tr)  
ORCID: <https://orcid.org/0000-0001-6349-7745>

## MAKALE BİLGİLERİ

## ÖZ

## Makale Geçmişi:

Geliş 18 Ekim 2024  
Revizyon 27 Kasım 2024  
Kabul 12 Aralık 2024  
Online 23 Aralık 2024

## Anahtar Kelimeler:

Makine öğrenmesi, Krigleme,  
Demir yatağı

Bu çalışmada günümüzde maden kaynak kestiriminde kullanılmaya başlanan derin sinir ağları, destek vektör makineleri ve XGBoost yaklaşımları kullanılarak bir demir yatağında tenör kestirimleri gerçekleştirilmiştir. Elde edilen sonuçlar endüstride yaygın bir şekilde kullanılan krigleme yöntemi ile karşılaştırılmıştır. Çalışma için öncelikle demir yatağı katı modeli yapılmış ve bu katı modeli temsil eden blok model oluşturulmuştur. Daha sonra girdi olarak kompozitlerin X, Y ve Z değerleri kullanılmış çıktı olarak ise tenör değerleri dikkate alınmıştır. Yukarıda değinilen üç makine öğrenmesi yaklaşımı için modeller ayrı ayrı eğitilmiştir. Yaklaşımların kendine has parametrelerinin tahmininde deneme yanılma yöntemi tercih edilmiştir. Eğitilen modeller ile blok model kestirimleri gerçekleştirilmiştir. Sonuçlar makine öğrenme algoritmalarının da yaygın kullanılan krigleme gibi yumuşatma özelliğinin bulunduğunu göstermektedir. Diğer bir deyişle, elde edilen sonuçların standart sapması kompozitlerin standart sapmasından düşüktür. Diğer bir önemli bulgu da makine öğrenme yöntemlerinin veri kümesi dışında bulunan değerleri tahmin edecek şekilde sonuçlar üretmesidir. Bu durum konumsal tenör kestirimlerinde istenilen bir özellik değildir. Ayrıca eğitilen modeller genel itibarı ile kompozitlerin ortalamalarına yakın sonuçlar çıkarsa da Derin Sinir Ağları modeli kompozitlerin ortalamasından ciddi sapma göstermiştir. Bu durum tüm makine öğrenme yaklaşımlarının doğrudan konumsal kestirimde kullanılmayacağını ve elde edilen sonuçların dikkatlice incelenmesi gerektiğini göstermektedir.

## ARTICLE INFO

## Article history:

Received 18 October 2024  
Received in revised form 27 November 2024  
Accepted 12 December 2024  
Available online 23 December 2024

## Keywords:

Machine Learning, Kriging, Iron  
ore

Doi: 10.24012/dumf.1569827

\* Sorumlu Yazar

## ABSTRACT

In this study, grade estimations were performed at an iron deposit using deep neural networks, support vector machines and XGBoost approaches, which are increasingly common in mineral resource estimation today. The results obtained were compared with the kriging method, which is widely used in the industry. To carry out the studies, firstly a solid model of the iron deposit was made and a block model representing this solid model was created. Then, the X, Y and Z values of composites were used as input and the grade values were considered as output. Models were trained separately with the three machine learning approaches mentioned above. The trial-and-error method was preferred in estimating the unique parameters of the approaches. Block model estimations were performed with the trained models. The results show that machine learning algorithms also have smoothing effect such as kriging, which is widely used. In other words, the standard deviation of the results obtained is lower than the standard deviation of the composites. Another important finding is that machine learning methods can be trained to predict values found outside the dataset. This is not a desired feature in spatial grade estimations. In addition, although the trained models generally produced results close to the average of the composites, the Deep Neural Network model showed serious deviation from the average of the composites. This shows that not all machine learning approaches can be used directly in spatial prediction and the results obtained should be examined carefully.

## Giriş

Yeryüzünde çeşitli jeolojik süreçler sonucunda oluşan ve ekonomik bir şekilde çıkarılabilen her türlü katı oluşum maden kaynağı olarak nitelendirilebilir. Bu oluşumlar genellikle kalite değişkeni (kalorifik değer, kül, nem vb.) ya da birim kütledeki metal miktarı olarak tanımlanan tenör değerleri ile karakterize edilir. Metalik maden kaynaklarında tenör, oluşum şartları gereği konuma bağlı değişkenlik göstermektedir. Tenör değerlerinin cevher yatağının örneklenmemiş kısımlardaki değerlerinin tahmin edilmesi ise “kestirim” olarak adlandırılmaktadır.

Maden kaynağı kestirimi, madencilik sektöründe ekonomik sürdürülebilirlik, kaynak yönetimi, risk azaltma, mevzuata uygunluk, teknolojik ilerlemeler ve çevresel etkilerin azaltılması için temel sağlayan kritik bir süreçtir [1]. Maden kaynaklarının tahmininde genellikle sondajlardan elde edilen veriler kullanılır. Kaynak modelin, sondaj verileri ile uyumlu olması beklenir. Sondaj verileri ile uyumlu bir kaynak model gerçek rezerve en yakın bilgiye ulaşılmasını sağlar ve bu sayede madencilik yatırım projelerinin daha gerçekçi ve verimli olmasına yardımcı olur. Bu süreç, aynı zamanda maden çıkarma süreçlerinin hassas bir şekilde planlanmasına olanak tanıyarak kaynakların verimli ve sürdürülebilir kullanımını sağlamakla birlikte atıkların ve çevresel etkinin en aza indirilmesine yardımcı olur. Ayrıca güvenilir kaynak tahmini, finansal ve operasyonel riskleri azaltarak, yatırım kararları için sağlam bir temel sunar ve proje finansmanının elde edilmesine katkı sağlar. Kaynak kestiriminde karmaşık jeostatistiksel yöntemlerin ve hesaplamalı modellerin kullanılması aynı zamanda jeoloji bilimi ve maden mühendisliğindeki ilerlemelere de yön vermektedir. Bunlara ek olarak kaynak kestirimi çevresel yönetim ve rehabilitasyon planlamasına yardımcı olarak madencilik faaliyetlerinin çevresel ayak izinin en aza indirilmesinde önemli rol oynamaktadır.

Jeostatistik, modern maden kaynağı kestiriminde çok önemli bir rol oynamaktadır. Jeostatistiksel yöntem, örneklenmemiş konumlardaki içkestirim (interpolasyon) değerlerini modelleyen variogram analizi ve krigleme gibi ileri matematiksel yöntemleri içerir. Sıklıkla kullanılan bir matematiksel yöntem olan krigleme, temel olarak sondajlar sonucunda elde edilen analiz verilerinin kullanılması ile örnek toplanmamış kısımlardaki tenör değerlerinin kestirilmesini sağlar. Yöntemin temel yaklaşımı, içerisinde barındırdığı krigleme denklemleri ile örneklem değerlerinin kestirilmek (tahmin edilmek) istenen alan üzerindeki ağırlıklarının yansız bir şekilde elde edilmesi şeklindedir. Böylece örneklenmemiş alanlardaki tenör değerleri kestirilebilmektedir. Cevher yataklarından sondajlar ile toplanan bu veriler genellikle eş uzunlukta değildir. Ancak, krigleme yaklaşımı eş uzunluklu verilerin kullanılmasını gerektirir. Bu sebepten bu veriler eşit değerlere dönüştürülür. Bu dönüştürülmüş yeni değerler ise kompozit olarak adlandırılmaktadır. Dönüşüm işlemi yani kompozitleme, oldukça basit bir şekilde eş uzunlukta aralıklar içerisinde düşen verilerin uzunluk ağırlıklı ortalamalarının alınmasından ibarettir.

Mevcut klasik yaklaşımlar olan krigleme, ters uzaklık ve en yakın komşu yöntemleri, maden kaynaklarının konumsal değişkenliğini ve dağılımını anlamak için bir çerçeve sağlar.

Öte yandan, sinir ağları, destek vektör regresyonu ve evrişimli sinir ağlarını içeren makine öğrenimi teknikleri, jeolojik veriler içindeki karmaşık, doğrusal olmayan ilişkileri ele almak için güçlü araçlar sunar. Bu yöntemler, kaynak tahminlerinin doğruluğunu artırmak için büyük veri kümeleri üzerinden eğitilmelerine dayanır.

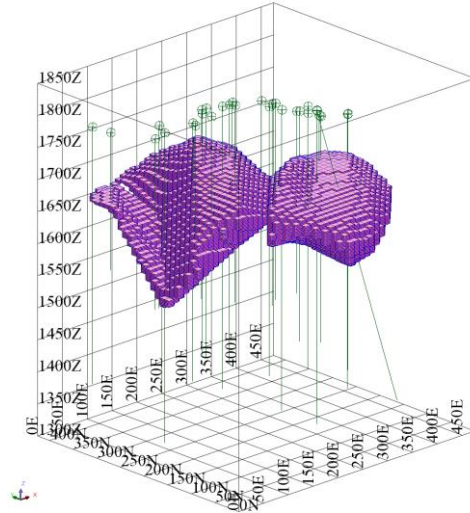

Makine öğrenimi ile jeostatistik tekniklerin karşılaştırılması çeşitli nedenler yüzünden çok önemlidir. Krigleme gibi jeostatistiksel yöntemler, mekansal verileri modelleme ve niceliksel belirsizlikle güvenilir tahminler sağlama konularında başarılı sonuçlar vermek için geliştirilmiştir. Buna karşılık, makine öğrenimi teknikleri büyük veri kümelerini yönetmede ve karmaşık, doğrusal olmayan ilişkileri modellemede başarılıdır. Bu alternatif yaklaşımların karşılaştırılmasına yönelik çalışmalar halen aktif bir araştırma konusudur. Bu çalışmalar temel olarak sadece makine öğrenme algoritmalarının kullanıldığı ve makine öğrenme algoritmaları ile klasik yöntemlerin karşılaştırıldığı araştırmalar olmak üzere iki ana kategoriye ayrılabilir. Mevcut çalışmalar genellikle maden kaynak kestirimine yönelik olmakla birlikte maden varlıklarının varlığının bulunmasına yardımcı olmak amacıyla da gerçekleştirilmiştir. Çalışmalara konu olan maden varlıkları genellikle demir, kurşun, çinko, bakır ve altın gibi metalik yataklardır. Birinci kategoriye giren yani sadece makine öğrenme algoritmalarının maden kaynak kestiriminde kullanılabilirliği konusu demir yatakları bazında gösterilmiştir [2, 3]. Bu çalışmaların ortak yanı, mevcut çalışmada olduğu gibi, Derin Sinir Ağlarının (DSA) demir yataklarında kaynak kestirim amacıyla kullanılmış olmasıdır. Ayrıca yine klasik yöntemlerle kıyas yapılmadan kurşun ve çinko varlıklarının belirlenmesinde de DSA'nın kullanılabilirliği belirtilmiştir [4]. Benzer şekilde başka bazı çalışmalarda Destek Vektör Makinaları (DVM) ve DSA'nın maden kaynak kestiriminde ve varlığının modellenmesinde kullanılabilirliği bildirmiştir [5-11]. İkinci kategoriye düşen, makine öğrenmesi ile kıyas yapan çalışmalar, temel olarak üç alt gruba ayrılabilir. Bu çalışmalardan bazıları krigleme gibi klasik kestirim yöntemlerinin daha iyi sonuçlar ürettiğini belirtmiş [12-15], bazı çalışmalar ise buna zıt olarak makine öğrenme yöntemlerinin krigleme yönteminden daha iyi sonuçlar ürettiğini belirtmiştir [14, 16-21]. Son alt gruptaki çalışmalar ise makine öğrenmesinin Krigleme gibi klasik yöntemlere bir alternatif olarak kullanılabilirliğini belirtmiştir olup kıyas yapmamışlardır [22-26]. Ayrıca makine öğrenmesi yaklaşımlarından DSA ve DVM'nin hangisinin daha iyi sonuçlar ürettiğine ilişkin birbiri ile çelişen yayınlar da mevcuttur [27-29]. Bu çalışmalardan görüldüğü üzere klasik ve yeni gelişen yöntemlerden hangilerinin daha iyi sonuçlar ürettiği halen tartışmaya açık bir konudur. Bu sebepten, bu belirsizliğin azaltılmasına yönelik çalışmalara ihtiyaç duyulmaktadır.

Bu çalışmada, günümüzde sıklıkla kullanılan krigleme yöntemi ile makine öğrenme yöntemlerinden olan Derin Sinir Ağları (DSA), Destek Vektör Makinaları (DVM) ve eXtreme Gradient Boosting (XGBoost) kullanılarak bir demir yatağında kestirimler gerçekleştirilmiştir. Tüm kestirimlerde aynı kompozitler kullanılmış ve bu kompozitlerde koordinatları temsil eden X, Y ve Z değerleri ile Fe tenör değerleri dikkate alınmıştır. Kestirimler için yöntemlerin doğası gereği farklı adımlar izlenmiştir. Ancak makine

öğrenmesinde modellerin eğitilebilmesi için girdi olarak X, Y ve Z değerleri yani kompozit lokasyonları kullanılırken çıktı olarak da Fe değerleri kullanılmıştır. Bilindiği üzere, genellikle, tenör verileri yer yüzünden aşağı doğru yapılan sondajlardan alınan numuneler üzerinden elde edilmektedir. Dolayısı ile sondajlardan elde edilen verilerin koordinatları birbirlerinden farklıdır. Girdi olarak kullanılan X, Y ve Z değerleri eşit uzunluklardaki kompozit değerlerinin orta noktalarının koordinatlarını ifade etmektedir. X değeri nirengi noktasına göre sağa yönünü, Y değeri yukarı yönünü ve Z değeri ise kompozitlerin kotunu temsil etmektedir. Çıktı olarak kullanılan Fe değeri ise bu koordinatlara tekabül eden Demir (Fe) kompozit değerleridir. Önceden belirtildiği gibi, çıktı olarak kullanılan Fe kompozitleri sondajların farklı kotlarından toplanan numuneler üzerinden yapılan kimyasal analizlere dayanmaktadır. Sonuç olarak krigleme, DSA, DVM ve XGBoost ile elde edilen kestirim sonuçları karşılaştırılmıştır. Karşılaştırma için kompozit değerleri baz alınmış ve elde edilen özet istatistiklerin kompozit özet istatistiklerinden sapma değerleri kullanılmıştır.

### Çalışma Sahası ve Yöntem

Bu çalışmada krigleme, DSA, DVM ve XGBoost yöntemleri bir demir yatağındaki Fe tenörlerinin kestirimi açısından karşılaştırılmıştır. İlgili saha Türkiye’de bulunmakla birlikte veri gizliliği nedeni ile tam konumu belirtilmemiştir. İlgili başka bir çalışmada sahadaki düşük tenörlü kısımlar değerlendirilmiş olmakla birlikte bu çalışmada sadece yatağın yüksek tenörlü kısımları dikkate alınmıştır [21]. Bu yatağa ilişkin sondajlar, demir cevheri oluşumunu temsil eden katı model ve tenör kestirimlerinin yapıldığı blok model Şekil 1’de gösterilmiştir.



Şekil 1 Yüksek tenörlü zonu temsil eden katı model (üst) ve blok model (alt)

Şekil 1’den görüldüğü üzere yüksek tenörlü zon yatağın ortasında incelenerek birbirleri ile bağlantılı iki küme halinde davranmaktadır. Cevherleşme doğu batı ekseninde yaklaşık olarak 420 m, kuzey güney ekseninde 400 m civarında yayılırken kalınlığı değişken olup 30 m ile 110 m arasında değişmektedir. Cevher derinliği 70 ile 260 m arasında değişmektedir.

Toplamda 30 adet sondaj yapılmış olup bu sondajlardan yüksek tenör olarak tanımlanan kısımlardan toplamda 618 adet veri toplanmıştır. Bu veriler karot numunelerinden yapılan analizlere dayanmaktadır. Belirli aralıktaki karotlar öncelikle ikiye bölünmüş olup, numunelerin bir yarısı şahit olarak karot sandığında saklanmış geriye kalan yarısı ise analize gönderilmiştir. Numune aralıkları eş uzunlukta değildir. Önceden de belirtildiği üzere, eş uzunlukta olmayan veriler üzerinden jeostatistiksel analiz ve kestirimler yapılamayacağından kompozitleme işlemi yapılmıştır. Kompozitleme işleminin temel hedefi eş uzunlukta olmayan ham tenör verilerinin, eş uzunlukta verilere dönüştürülmesidir. Bu dönüşüm işlemi için aşağıdaki formülasyon kullanılmıştır (Denklem (1)).

$$\beta = \sum_{i=1}^n \frac{O_i}{K} Z_i \quad (1)$$

Burada,  $\beta$  kompozit değerini,  $O_i$  örneklem uzunluğunu,  $K$  kompozit boyunu ve  $Z_i$  değeri karotlar üzerinden toplanan örneklem değerini göstermektedir.  $Z_i$  değeri sadece ilgili aralığa düşen verileri kapsamaktadır. Kompozitleme işlemi özetle bir sondajda cevher kesen ilk kısımdan başlayıp cevherleşme bitene kadar olan kısımların eş uzunluklardaki aralıklara bölünmesi ile başlar. Daha sonra bu aralıklara düşen veriler belirlenir ve sonrasında bu veriler Denklem (1)’de gösterildiği gibi oluşturulur. Bu işlem tüm sondajlar için tekrarlanır.

Denklem (1)’den de görüldüğü üzere  $Z_i$  ve  $O_i$  değerleri numunelere dayanmaktadır. Ancak Denklem (1)’de yalnızca  $K$  yani kompozit boyu değiştirilebilmektedir. Bu değer genellikle karotlardan toplanan örneklemelerin ortalama uzunluğuna eşit seçilir. Mevcut karot verileri incelendiğinde

ortalama örneklem uzunluğunun 1 m olduğu gözlenmiştir. Bu sebepten, mevcut ham verilerin 1 m boyunda kompozitleri elde edilmiştir. Cevherleşme sondajlar bazında incelendiğinde oldukça değişkendir. Bazı sondajlarda yalnızca 4 m'lik yüksek tenörlü cevherleşme tanımlanmışken bu değer bazı sondajlarda ise yaklaşık olarak 60 m'ye kadar çıkmaktadır. Bu durumda sondajlardan toplanan veri sayısı da aynı olamamaktadır. Bu sayı sondajda kesilen cevher kalınlığına göre artmaktadır. Bu sebepten bazı sondajlarda yalnızca dört adet kompozit veri oluşmuşken bu sayı diğer sondajlarda 60'a kadar çıkmıştır. Oluşan toplam kompozit sayısı 635'tir. Kompozitleme sonucu elde edilen veriler ve ham verilere ait özet istatistikler Tablo 1'de verilmiştir. Kompozitleme, maden kaynak kestiriminde oldukça yaygın kullanıldığından bu işlem için paket programlar kullanılmaktadır. Bu çalışmada kompozitleme için NetproMine isimli madencilik yazılımı kullanılmıştır.

Tablo 1. Ham veriler ve kompozitlere ait özet istatistikler

	Ham veriler	Kompozitler
Veri sayısı	618	635
En düşük	30,76	30,76
Ortalama	54,45	54,50
Ortanca	56,50	57,60
En yüksek	61,43	61,43
Standart Sapma	6,84	6,82

Tablo 1'de görüldüğü üzere ham ve kompozit değerlerin özet istatistikleri oldukça benzerdir. Bu kompozitleme için beklenen ve istenen bir durumdur. Veri sayıları bakımından kompozitlerin sayısının fazla olması örnek toplama sıklığının bazı yerlerde 1 m'den daha yüksek olduğunu göstermektedir. Ham veriler ile kompozitler arasındaki küçük istatistiksel farkların da sebebi bu durumdur.

## Yöntem

Bu çalışmada kullanılan krigleme, DSA, DVM ve XGBoost yöntemleri aşağıda açıklanmıştır.

### Krigleme

Krigleme, jeostatistiksel bir içkestirim yöntemi olup, özellikle maden mühendisliği ve çevre bilimlerinde yaygın olarak kullanılır. Bu yöntem, Güney Afrikalı maden mühendisi Daniel Krige tarafından 1950'lerde geliştirilmiştir [30]. Krigleme, belirli bir alanda toplanan örnek verilerin analizine dayanır ve veri noktaları arasındaki mekânsal ilişkiyi tanımlamak için variogram kullanır. Variogram, iki nokta arasındaki mesafe ile bu noktalar arasındaki veri değerlerinin farkının karesi arasındaki ilişkiyi gösterir. Krigleme, genel itibar ile tahmin edilecek noktaya en yakın veri noktalarına daha fazla ağırlık vererek tahmin yapar ve bu ağırlıklar, variogramdan elde edilen konumsal ilişki bilgisine dayanarak hesaplanır. Her bir tahmin noktası için bir değer ve bu tahminin hata oranı sağlanır, bu da tahminlerin güvenilirliğini değerlendirmede önemli bir rol oynar [30]. Krigleme yöntemi oldukça iyi bilindiğinden bu çalışmada matematiksel temellerinin verilmesine ihtiyaç duyulmamıştır.

## Derin Sinir Ağları (DSA)

Derin Sinir Ağları (DSA), insan beyninin yapısından ve işlevinden ilham alan karmaşık modellerdir. DSA'lar genel itibari ile girdiler, çıktılar ve bunlar arasındaki ilişkinin modellendiği katmanlardan oluşmaktadır. Bu katmanlar her biri nöron olarak adlandırılan işlemciler kümesinden oluşur. Her nöron, girdilerinin ağırlıklı bir toplamını alıp bu toplama bir yanlılık (bias) terimi ekler ve bir aktivasyon fonksiyonu kullanarak değerleri işler. Aktivasyon fonksiyonun en önemli işlevi doğrusal olmayan ilişkilerin de modellenmesini sağlamaktır. Böylece, oluşan ağ yapısı girdi ve çıktılar arasındaki karmaşık ilişkilerin modellenmesini sağlar [31-33].

Bir DSA'nın işleyişi temel olarak nöronlar üzerinden ağırlıklı toplamaların oluşturulması, sonrasında bu sonuçların aktivasyon fonksiyonları ile değerlendirilmesi ve kayıp fonksiyonunun minimize edilmesine dayanır. Bu minimizasyon için ileri ve geri yayılma gibi teknikler kullanılır. Bu adımlar aşağıda kısaca açıklanmaktadır.

**Ağırlıklı Toplam:** Her giriş  $x_i$  karşılık gelen bir ağırlık olan  $w_i$  ile çarpılır. Nöron, girdilerinin ağırlıklı toplamını aşağıdaki gibi hesaplar (Denklem (2)):

$$z = \sum_{i=1}^n w_i x_i + b \quad (2)$$

Burada, b yanlılık terimi olup n toplam nöron sayısını ifade eder.

**Aktivasyon Fonksiyonu:** Ağırlıklı toplam z daha sonra aktivasyon fonksiyonu olan  $\phi(z)$  işlemcisine tabi tutulur. Önceden de belirtildiği üzere bu aktivasyon işlemcisi doğrusal olmayan ilişkilerin modellenmesini sağlar. Yaygın aktivasyon işlemcileri aşağıdaki gibidir (Denklem (3)):

$$\begin{aligned} \text{Sigmoid}(x) &= \frac{1}{1 + e^{-ax}} \\ \text{Tanh}(x) &= \frac{(e^x - e^{-x})}{(e^x + e^{-x})} \\ \text{ReLU}(x) &= \max(0, x) \end{aligned} \quad (3)$$

Bir DSA'nın eğitimi, tahmin edilen çıktı ile gerçek çıktı arasındaki hatayı en aza indirecek şekilde ağırlıkların ve yanlılığın belirlenmesiyle gerçekleştirilir. Önceden belirtildiği üzere, bu süreç temel olarak ileri yayılma, kayıp fonksiyonunun değerlendirilmesi ve sonuçta geri yayılma adımları ile gerçekleştirilir.

**İleri Yayılma (forward propagation):** Bir çıktı oluşturmak için girdi verilerinin bir ağ üzerinden ileri yönde beslendiği yaklaşımdır.

**Kayıp Fonksiyonu:** Regresyon amacı ile eğitilen bir ağda Ortalama Hatanın Karesi (OHK) gibi bir kayıp fonksiyonu kullanarak kayıp yani beklenen değerden sapma (hata) hesaplanır (Denklem (4)):

$$\text{OHK} = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (4)$$

**Geri yayılım:** Denklem (2)'de gösterilen ağırlıkların makul bir süre içerisinde bulunmasını sağlayan adımdır. Genel yapı olarak çıktı katmanındaki nöronların girdi değerlerine göre,

çıkı katmanındaki nöronların bir önceki katmanla arasındaki değerlere göre kısmi türevinin alınarak zincir kuralının uygulanmasına dayanır. Böylece katmandaki ağırlıklar güncellenerek Denklem (4)'deki OHK değerinin en düşük olduğu ağırlıklar bulunur [34]. Böylece DSA modeli eğitilmiş olup yeni girdi değerleri için tahminlerde bulunabilir.

### Destek vektör makineleri (DVM)

Destek Vektör Makineleri (DVM), sınıflandırma ve regresyon problemleri için kullanılan denetimli öğrenme yaklaşımlarıdır. DVM'nin temel hedefi iki sınıftan birbirinden ayıran en geniş doğrusal koridorun bulunmasıdır. Diğer birçok makine öğrenme yaklaşımlarında olduğu gibi amaç fonksiyonunun minimizasyonuna dayanmaktadır. Amaç fonksiyonu ise Denklem (5)'teki gibi tanımlanabilir.

$$\frac{1}{2} \| \mathbf{w} \|^2 + C \sum_{i=1}^n (\xi_i + \xi_i^*) \quad (5)$$

Burada,  $\mathbf{w}$  ağırlık vektörü,  $C$  fonksiyonun düzlüğü ile küçük sapmaları tolere edildiği miktar arasındaki dengeyi belirleyen bir düzenleme parametresi olup değeri 0 ile sonsuz arasındadır,  $\xi_i$  ve  $\xi_i^*$  ise gerçek değerlerden epsilon tolerans marjına olan mesafeyi temsil eden değişkendir. Diğer taraftan bu değişkenler gevşek değişken olarak da isimlendirilmektedir. Amaç fonksiyonu Denklem (6)'daki kısıtlamalara tabidir.

$$\begin{aligned} y_i - (\mathbf{w} \cdot \mathbf{x}_i + b) &\leq \epsilon + \xi_i \\ (\mathbf{w} \cdot \mathbf{x}_i + b) - y_i &\leq \epsilon + \xi_i^* \\ \xi_i, \xi_i^* &\geq 0 \end{aligned} \quad (6)$$

Burada  $y_i$  gerçek bir değer,  $x_i$  özellik vektörü,  $b$  sapma ve  $\epsilon$  ise toleransı temsil eder.

DVM çözümler için genellikle Lagrange çarpanları kullanılır ve optimizasyon fonksiyonu dual forma dönüştürülür. Genel itibari ile bir çekirdek fonksiyon sayesinde veriler herhangi bir dönüşüme gerek kalmadan doğrudan çalışılabilir durumda olur. Son olarak da nihai kestirici fonksiyon ise Denklem (7)'deki gibi yazılabilir;

$$f(\mathbf{x}) = \sum_{i=1}^n (\alpha_i - \alpha_i^*) K(\mathbf{x}_i, \mathbf{x}) + b \quad (7)$$

Burada  $K$  ilgili çekirdek fonksiyonu,  $b$  ise düşey eksendeki sapma terimini temsil etmektedir [35, 36].

### XGBoost

DSA ve DVM gibi eXtreme Gradient Boosting (XGBoost) yöntemi de denetimli öğrenme için kullanılan bir yaklaşımdır. XGBoost gradyan artırmaya (gradient boosting) dayanan bir yöntemdir. Verimliliği ve doğruluğu nedeniyle makine öğrenimi yarışmalarında ve pratik uygulamalarda yaygın olarak kullanılmaktadır [37].

XGBoost temel olarak karar ağaçlarına dayanmaktadır. Yöntem özünde, her ağacın bir öncekinin hatalarını düzeltmeye çalıştığı, sıralı bir karar ağaçları topluluğu oluşturma yaklaşımını benimsemektedir. XGBoost'taki amaç

fonsiyonu, aşırı uyumu önlemek için bir kayıp fonksiyonu ile bir düzenleme terimini birleştirir. Kayıp fonksiyonu Denklem (8)'deki gibi hesaplanabilir;

$$L(y, \hat{y}) = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (8)$$

Burada  $y_i$  gerçek değer,  $\hat{y}_i$  kestirilen değer,  $n$  ise veri sayısını ifade eder. Düzenleme terimi ise Denklem (9)'daki gibidir;

$$\Omega(f) = \gamma T + \frac{1}{2} \lambda \sum_{j=1}^T w_j^2 \quad (9)$$

$T$  Ağaçtaki yaprak sayısını,  $w_j^2$   $J$  yaprağındaki ağırlığı,  $\gamma$  ve  $\lambda$  terimleri ise aşırı öğrenmeyi engellemek için kullanılan parametrelerdir.

Sonuç olarak nihai amaç fonksiyonu Denklem (10)'daki gibi ifade edilebilir:

$$\text{Obj} = \sum_{i=1}^n L(y_i, \hat{y}_i) + \sum_{k=1}^K \Omega(f_k) \quad (10)$$

Burada  $K$  ağaç sayısını ifade eder.

XGBoost, amaç fonksiyonunu minimize etmek için gradyan artırma kullanır. Temel yaklaşım, önceki ağaçların hatalarını tahmin eden yeni ağaçlar eklemektir. Model Denklem (11)'deki gibi güncellenir:

$$\hat{y}_i^{(t)} = \hat{y}_i^{(t-1)} + f_t(\mathbf{x}_i) \quad (11)$$

$f_t(\mathbf{x}_i)$  iterasyondaki tahmini,  $\hat{y}_i^{(t-1)}$  ise iterasyondaki yeni ağacın kestirimini ifade eder.

XGBoost'taki her ağaç, aşağıdaki amaç fonksiyonunu minimize etmek için Denklem (12)'de olduğu gibi oluşturulur:

$$\text{Obj}^{(t)} = \sum_{i=1}^n [g_i f_t(\mathbf{x}_i) + \frac{1}{2} h_i f_t(\mathbf{x}_i)^2] + \Omega(f_t) \quad (12)$$

Burada,  $g_i = \partial_{\hat{y}_i^{(t-1)}} L(y_i, \hat{y}_i^{(t-1)})$  birinci dereceden gradyan

$(h_i = \partial_{\hat{y}_i^{(t-1)}} 2L(y_i, \hat{y}_i^{(t-1)}))$  ise ikinci dereceden gradyandır.

XGBoost boş bir ağaç yapısında başlayarak, Denklem (13)'de gösterilen kazanç fonksiyonunu minimize etmek için yaprakları art arda böler.

$$\text{Kazanç} = \frac{1}{2} \left[ \frac{G_L^2}{H_L + \lambda} + \frac{G_R^2}{H_R + \lambda} - \frac{(G_L + G_R)^2}{H_L + H_R + \lambda} \right] - \gamma \quad (13)$$

$G_L$  ve  $G_R$  sol ve sağ bölmeler için gradyanların toplamı iken  $H_L$  ve  $H_R$  sol ve sağ bölmeler için Hessianların toplamıdır. Yeni bir gözlem ( $x$ ) için nihai tahmin, tüm ağaçların tahminlerinin toplamıdır (Denklem (14)):

$$\hat{y} = \sum_{k=1}^K f_k(\mathbf{x}) \quad (14)$$

Bu yaklaşım, XGBoost'un yüksek doğruluk ve sağlıklı elde etmesini sağlar [37].

## Bulgular ve Tartışma

Krigleme yöntemi günümüzde iyi bir şekilde anlaşıldığı için krigleme adamları ve bu adımlardaki parametrelerin belirlenmesi genel kabul gören bir hal almıştır. Bu genel kabul gören adımlar uygulanarak öncelikle deneysel variogramlar hesaplanmış, sonrasında model variogramlar uyarlanmış, bu variogramların kullanılabilirliği test edilmiş ve sonuç olarak bu model variogramlar kullanılarak blok bazında kestirimler yapılmıştır. Elde edilen variogram modeli izotrop bir küresel modeldir. Bu modelin külçe etki değeri 1,5, eşik değeri 45 ve yapısal uzaklığı 120 m'dir. Tarama küresi ise tüm blokların tek seferde kestirilmesine yetecek şekilde 200 m yarıçapında seçilmiştir. Tüm yapılan krigleme işlemlerinde NetproMine isimli madencilik yazılımı kullanılmıştır.

Makine öğrenmesine ilişkin yöntemlerde model doğrulama adımları iyi bilinen krigleme yönteminin aksine genel kabul gören bir hal almamıştır. Bu sebepten, bu çalışmada deneme yanılma yöntemi ile model parametreleri belirlenmiştir. Makine öğrenmesine yönelik yapılan tüm işlemlerde Python programlama dili kullanılarak yazılan programlar çalıştırılmıştır. Ayrıca makine öğrenme yaklaşımları genellikle işlem yoğun olduğundan günümüz standartlarında bir bilgisayar ile kestirimler yapılmıştır. Kestirimde kullanılan bilgisayar 3,00 GHz işlem gücüne sahip 13. nesil Intel bir işlemcidir. Bilgisayarda toplamda 32 çekirdek bulunmakla birlikte 64 GB'lık bir RAM bulunmaktadır. Tüm yöntemlerde yapılan kestirimler eğitim işlemi bittikten sonra toplamda 26834 adet blok için kestirimler birkaç saniye sürmüştür. Blok boyutları sabit olup X, Y ve Z yönlerinde sırası ile 10, 10 ve 2 m olarak belirlenmiştir.

Derin sinir ağları ile kestirim için diğer yöntemlerde olduğu gibi girdi olarak kompozitlerin X, Y ve Z değerleri kullanılırken hedef değer (çıktı) olarak Fe tenörleri kullanılmıştır. Ayrıca DSA ve DVM ile kestirimlerde tüm girdiler normalize edilmiştir. Birçok normalizasyon yöntemi bulunmakla birlikte bu çalışmada Denklem (15)'te verilen min-maks normalizasyonu kullanılmıştır.

$$D_n = \frac{\tau - \tau_{min}}{\tau_{max} - \tau_{min}} \quad (15)$$

Burada;  $D_n$  normalize edilmiş değer,  $\tau$  değişken,  $\tau_{min}$  ve  $\tau_{max}$  ise sırası ile değişkenin en düşük ve en yüksek değerlerini ifade eder. Normalizasyon adımı DSA ve DVM için gerçekleştirilmiş olup, XGBoost için yapılmamıştır. DSA ve DVM için yapılmasının sebebi ise ilgili yaklaşımların normalize edilmiş değerler üzerinden daha hızlı bir şekilde eğitilmesini sağlanmasıdır. Model eğitimleri ve kestirimler aynı normalizasyon değerleri kullanılarak yapıldığından kestirim sonuçları bu adımdan etkilenmemiştir.

Bunun sebebi bloklara da aynı normalizasyonun uygulanmasıdır. Kestirimler normalize edilmiş X, Y ve Z değerleri üzerinden yapılmış olup, bloklar kestirimlerden sonra eski koordinatlarına geri getirilmiştir. Fe değerleri için herhangi bir normalizasyon uygulanmamıştır. Bunun sebebi ise Fe değerlerinin hali hazırda düşük değerler olan 30 ile 61 arasında değişmesidir.

Bu işlem DSA modelinin kısa süre içerisinde eğitilmesini sağlayan bir adımdır. DSA ile yapılan kestirimlerde kompozit verilerin %70 derin sinir ağına eğitmek, %15'i eğitimi doğrulamak ve geriye kalan %15'i ise eğitilen modelin testi için kullanılmıştır.

DSA gizli tabakalarında Tanh aktivasyon fonksiyonu kullanılmış, ancak Fe tenör değerlerine giden son çıktı tabakasında ise doğrusal fonksiyon kullanılmıştır. Maliyet fonksiyonunun minimizasyonunda gradyan azaltma (Gradient descent) yaklaşımı kullanılmıştır. Kullanılan maliyet fonksiyonu ortalama karesel hatadır. DSA'nın yapısı ise koordinatların beslendiği ilk tabaka, 15 düğüm noktasından oluşan iki tabaka ve çıktı tabakası olmak üzere toplamda 4 tabakadan oluşmaktadır. Model MSE'si değerlendirildiğinde 1000 optimizasyon adımında sonra en düşük değerlere ulaşıldığı görülmüştür. Ayrıca eğitim, test ve doğrulama adımlarındaki hedef ve kestirim değerleri arasındaki korelasyon katsayılarının ise sırası ile 0,78, 0,75 ve 0,77 olduğu gözlenmiştir. Değerlerin birbirlerine yakın çıkması modelin genelleme seviyesinin yeterli düzeyde olduğunu göstermektedir. Böylece eğitilen DSA modeli blokların kestirimlerinde kullanılmıştır.

Destek Vektör Makinesi (DVM) ile kestirimde DSA'ya benzer adımlar uygulanmıştır. Girdi olarak kullanılan X, Y ve Z değerleri ile çıktı olan Fe değerleri normalize edilmiştir. DSA dan farklı olarak DVM'ler çekirdek fonksiyonuna ihtiyaç duymaktadırlar. Bu çalışmada alternatifler arasından regresyon amaçlı en sık kullanılan Radyal Temelli Çekirdek fonksiyonu tercih edilmiştir. Diğer optimize edilmesi gereken parametreler ise epsilon ve C ceza parametreleridir. Bu parametrelerin modellenmesi için veri kümesi %80-%20 eğitim ve test olmak üzere iki gruba ayrılmıştır.

Yapılan deneme yanılma işlemi sonucunda C 10, epsilon 0,025 ve sigma parametresi ise 0,15 olarak belirlenmiştir. DSA'ya benzer şekilde blokların X, Y ve Z koordinat değerleri girdi olarak kullanılarak Fe değerleri her bir blok için kestirilmiştir. Kestirim sonuçlarına ve kompozitlere ait özet istatistikler Tablo 2'de verilmiştir.

Tablo 2. Kompozitler ve kestirim sonuçları

	Kompozit	Krigleme	DSA	DVM	XGBoost
Veri sayısı	236	26835	26835	26835	26835
En düşük	30,76	31,0	30,0	31,9	30,8
Ortalama	54,5	55,0	59,8	56,1	53,9
Ortanca	57,6	55,7	58,7	56,4	54,9
En yüksek	61,43	61,4	60,0	65,0	64,8
Standart Sapma	6,82	4,36	4,20	4,48	5,35



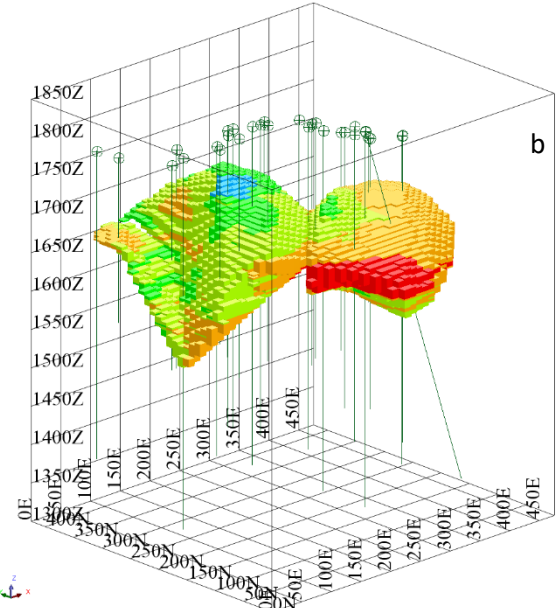

Tablo 2’de görüldüğü üzere tüm yöntemler yumuşatma özelliği göstermektedir. Diğer bir deyişle, elde edilen kestirim varyansları kompozitlerin varyansından düşüktür.

Tablo 3’te gösterilen istatistiklerin karşılaştırılması amacıyla kompozit istatistiklerden sapmaları gösterilmiştir.

Tablo 3. Kestirimlere ait istatistiklerin kompozit istatistiklerinden sapma değerleri.

Yüzdece sapma (%)	Krigleme	DSA	DVM	XGBoost
<b>En düşük</b>	0.8	-2.5	3.7	0.1
<b>Ortalama</b>	0.9	9.7	2.9	-1.1
<b>Ortanca</b>	-3.3	1.9	-2.1	-4.7
<b>En yüksek</b>	0.0	-2.3	5.8	5.5
<b>Standart Sapma</b>	-36.1	-38.4	-34.3	-21.6

Tablo 2’de görüldüğü üzere hiçbir yöntem kompozitler ile aynı istatistikleri üretmemiştir. Tablo 3’te gösterilen istatistiki farkların yüzdeleri incelendiğinde tek bir yöntemin tüm diğer yöntemlere üstünlük sağlaması gibi bir durum da oluşmamıştır. Her bir yöntemin öne çıktığı istatistikler farklıdır. Krigleme Ortalama ve en yüksek değer bazında diğer yöntemlerden öne çıkarken, XGBoost en düşük ve standart sapma bazında kompozitlere en yakın istatistikleri üretmiş olup, DSA ise ortanca bazında diğer yöntemlerden daha iyi sonuç üretmiştir. Şekil 2’de ise blok model kestirim sonuçları gösterilmiştir.



Şekil 2 Kestirimler sonucu oluşan Fe (%) değerleri a) Krigleme b) DSA c) DVM d) XGBoost

Şekil 2’de görüldüğü üzere kestirimlerin birbirlerine benzediği ve ayrıştığı durumlar vardır. Tüm kestirim yöntemleri cevherleşmenin güneydoğusunda yüksek tenörlü bir kısma işaret etmektedir. Benzer şekilde güneybatı kısımlarında ise değişkenliğin yüksek olduğu görece yüksek (%45-60 Fe arası) kısımlar mevcuttur. Genellikle ayrışan kısımlar ise yatağın merkezine yakın olan ve en üst kotlarda bulunan kısımlarda DSA ve DVM yöntemleri görece düşük tenörleri işaret etmektedir. Ayrıca sadece DVM ile yapılan kestirimler yatağın doğu kısmındaki sınırları oldukça yüksek olduğunu göstermektedir. DVM’nin neden böyle bir sonuç ürettiği bilinmemektedir. Bu duruma dikkatle yaklaşmak gerekmektedir. İlgili alandaki yüksek tenörlerin kesinlikle ek sondajlarla teyit edilmesi elzemdir.

Tablo 3’te görüldüğü üzere makine öğrenme yöntemlerinin bazılarında kompozitlerde görülen değerlerin dışında kestirim değerleri tespit edilmiştir. Bu durumla özellikle yatağın sınır kısımlarında karşılaşılmaktadır. Bunun sebebi ise ilgili kısımların eğitimde kullanılan X, Y ve Z değerlerinin dışında kalmasıdır. Diğer bir bakış açısı ile yatak sınırlarında sondaj bulunmadığından eğitilen modeller ilgili kısımlarda ekstrapolasyon yapmıştır. Bu sebepten bu kısımlardaki kestirimlere dikkatli yaklaşmak gerekmektedir. İlgili kısımların doğrulunun testi için ek veri toplanması tavsiye edilmektedir.

Günümüzde kaynak kestirimi, tenör modellemesi amacı ile kullanılan makine öğrenme yöntemleri kara kutu (black box) olarak çalışmaktadırlar. Diğer bir ifade ile elde edilen sonuçlara nasıl ve neden varıldığı bazı kurallara bağlı olarak belirlenirken sonuçlara varmak için eğitilen modellerin yorumlaması oldukça güç olup, genelde mümkün değildir. Bu sebepten mevcut jeostatistiksel yöntemlerde olduğu gibi variograma ait yapısal uzaklık, eşik değer ve külçe etkisi gibi kavramlardan bahsetmek söz konusu değildir. Makine öğrenmesinde, bu kavramlardan söz edilemeyeceği gibi buna benzer olan parametreler de bulunmamaktadır. Bu durum, belirtildiği üzere, makine öğrenme yöntemlerinin kara kutu yapısından kaynaklanmaktadır. Ayrıca makine öğrenmesi yaklaşımlarında kullanılan parametreler deneme yanılma yöntemi ile belirlenmiştir. Bu durum her zaman en uygun parametre değerlerinin bulunduğunu garanti etmemektedir. Bu çalışmada sistematik bir şekilde parametreler taranmış ve kompozitlerin istatistiklerine en yakın sonuçları veren parametreler kestirim parametreleri olarak belirlenmiştir.

## Sonuç

Maden kaynaklarının değerlendirmesindeki en önemli adımlardan birisi olan tenör kestirimi için günümüzde yaygın olarak krigleme kullanılsa da makine öğrenme algoritmaları alternatif olarak ortaya çıkmaktadır. Makine öğrenme yöntemlerinden DSA, DVM ve XGBoost algoritmalarının birlikte değerlendirildiği bir çalışma bulunmamaktadır. Bu çalışmada ilgili yöntemler karşılaştırılmıştır. Karşılaştırma

amacı ile bir demir yatağındaki Fe tenörleri belirtilen yöntemler ile kestirilmiştir. Kestirimler için kriglemede model variogramlar uyarlanırken diğer yöntemlerde ise yöntemlere özel parametrelerin tahminleri yapılmıştır. Makine öğrenmesi yöntemlerinin eğitilmesinde girdi olarak kompozitlerin X, Y ve Z değerleri kullanılırken çıktı olarak da Fe değerleri kullanılmıştır. Böylece eğitilen modellerin blok Fe tenörleri kestirilmiştir.

Kestirim sonuçları diğerlerine her açıdan üstünlük sağlayan bir yöntemin olmadığını göstermektedir. Krigleme ortalama ve en yüksek değer açısından üstün görünürken, XGBoost en düşük ve standart sapma açısından daha iyi sonuçlar üretmiştir. DSA ise ortanca değer bakımından en iyi sonucu üretmiştir. DVM’nin ise diğerlerine üstünlük sağladığı bir istatistik bulunamamıştır.

Krigleme diğer tüm yöntemlere her açıdan üstünlük sağlayamasa da kaynak kestiriminde bu yöntemin yaygın olarak kullanılmasının ilk sebebi 1950’lerden günümüze bilinmesi ve bu sebepten konuya aşına kişi sayısının daha çok olmasıdır. Ayrıca günümüzde alternatif olarak gelişen makine öğrenmesi yöntemleri, bu çalışmada görüldüğü gibi, her zaman istenen aralıklarda yani kompozit değerleri aralığında sonuçlar üretmeyi garanti etmemektedir. Bununla birlikte elde edilen sonuçların yorumlanması genellikle mümkün değildir. Makine öğrenme yöntemlerinde, kompozitler üzerinden eğitilen modellerin genel kestirici olarak beklenen özelliklerde sonuçlar üretmesi beklenirken bu beklenen sonuçların ulaşılabileceğini garanti etmemektedir. Bu duruma örnek olarak, DVM ile yapılan kestirimde yatak sınırlarında beklenmeyen yüksek tenörlü kısımlar ile karşılaşılmıştır. Ancak yöntemin doğası gereği bu durumun bir açıklamasının yapılması mümkün değildir. Bu gibi sebeplerden makine öğrenmesi ile kestirimler günümüzde halen akademik olarak araştırma seviyesinde olup, krigleme maden kaynak kestiriminde sıklıkla kullanılmaktadır.

Bu çalışmadan elde edilen bir diğer sonuç da bazı kestirim yöntemlerinin ekstrapolasyon yaparak kompozitlerin bulunduğu değer aralığı dışında kestirimler üretmesidir. Örneğin DSA en düşük değeri yaklaşık olarak kompozit en düşük değerlerinden %2,5 daha düşüktür. Yani kestirim değerlerinin en düşük değeri kompozitlerden daha düşüktür. Benzer şekilde DVM ve XGBoost’da elde edilen kestirim değerlerinin en yüksek değerleri de kompozitlerden yaklaşık olarak %5 daha yüksektir. Bu durum tenör kestirimlerinde istenmeyen bir durumdur. Bunun sebebi ise hedef olan kompozit değerleri aralığı dışındaki bir kestirim değerinin gerçekçiliğinin sorgulanmaya açık bir durum olmasıdır. Krigleme de ise böyle bir durum söz konusu değildir. Bu sebepten makine öğrenmesine dayalı yöntemlerle yapılan kestirimlerde mutlak suretle bir uzmanın eleştirel bir şekilde inceleme yapması gerekmektedir.

Önceden belirtildiği üzere krigleme ile kestirim adımları genel kabul gören bir hal almıştır. Ancak bu genel kabul görmüş yaklaşımlar makine öğrenmesi ile kestirimlerde mevcut değildir. Tenör kestirimlerine ilişkin yapılan



çalışmalarda parametre belirleme yaklaşımları çeşitlilik göstermekle birlikte bu çalışmada deneme yanılma yöntemi kullanılmıştır. Ancak deneme yanılma yöntemi en iyi parametrenin belirlendiğini garanti etmemektedir. Bu sebepten konumsal tenör değerlerinin tahmininde makine öğrenmesine yönelik temel yaklaşımların endüstri pratiklerinden ve iyi örneklerden yola çıkarak daha genel kabul gören bir yapıya büründürülmesi gerekmektedir.

Ayrıca ileri dönem çalışmalarında kriglemenin doğrusal olmayan varyasyonlarının da karşılaştırmaya dahil edilmesi önerilmektedir. Özellikle çarpık dağılıma sahip veri kümelerinde log-normal Krigleme ve verilerin belirli bir kritik değeri aşma olasılıklarının belirlenmesi istenmesi durumunda ise Ayrıcı (disjunctive) Krigleme gibi doğrusal olmayan yöntemlere başvurulabilir. Bu çalışmaya konu olan veri kümesinde konumsal olarak ciddi bir çarpık dağılım gözlenmediğinden doğrusal olmayan krigleme yöntemlerine başvurulmamıştır.

### Teşekkür

Yazar, değerlendirme sürecinde bilgi birikimleri ve yapıcı eleştirileri ile makalenin bilimsel kalitesinin iyileştirilmesine katkıda bulunan anonim değerlendireciler ve editörlere içtenlikle teşekkür eder. Yazar, ayrıca, makalenin yazım aşamasında sunmuş oldukları katkılardan dolayı Dr. S. Yasin Kılıoğlu ve Dr. M. Suphi Ünal'a teşekkürü bir borç bilir.

### Kaynaklar

- [1] F. Atalay, M. S. Ünal, and S. Y. Kılıoğlu, "Bir Demir Yatağında Radyal Temelli Fonksiyon ve Ortalamasız Krigleme Kestirimlerinin Karşılaştırılması," *Avrupa Bilim ve Teknoloji Dergisi*, no. 27, pp. 303-310, 2021.
- [2] A. M. Albora, "Investigation of Bingöl Iron Ore Reserves Using Wavelet Cellular Neural Networks," *International Journal Of Scientific Advances*, vol. 2, no. 1, 2021, doi: 10.51542/ijscia.v2i1.9.
- [3] M. Badel, S. Angorani, and M. Shariat Panahi, "The application of median indicator kriging and neural network in modeling mixed population in an iron ore deposit," *Computers & Geosciences*, vol. 37, no. 4, pp. 530-540, 2011, doi: 10.1016/j.cageo.2010.07.009.
- [4] S. Chatterjee, S. Bandopadhyay, and D. Machuca, "Ore Grade Prediction Using a Genetic Algorithm and Clustering Based Ensemble Neural Network Model," *Mathematical Geosciences*, vol. 42, no. 3, pp. 309-326, 2010, doi: 10.1007/s11004-010-9264-y.
- [5] S. Dutta, D. Misra, R. Ganguli, B. Samanta, and S. Bandopadhyay, "A hybrid ensemble model of kriging and neural network for ore grade estimation," *International Journal of Mining, Reclamation and Environment*, vol. 20, no. 1, pp. 33-45, 2006, doi: 10.1080/13895260500322236.
- [6] V. Rodriguez-Galiano, M. Sanchez-Castillo, M. Chica-Olmo, and M. Chica-Rivas, "Machine learning predictive models for mineral prospectivity: An evaluation of neural networks, random forest, regression trees and support vector machines," *Ore Geology Reviews*, vol. 71, pp. 804-818, 2015, doi: 10.1016/j.oregeorev.2015.01.001.
- [7] B. Samanta, S. Bandopadhyay, and R. Ganguli, "Comparative Evaluation of Neural Network Learning Algorithms for Ore Grade Estimation," *Mathematical Geology*, vol. 38, no. 2, pp. 175-197, 2006, doi: 10.1007/s11004-005-9010-z.
- [8] M. Shabankareh and A. Hezarkhani, "Application of support vector machines for copper potential mapping in Kerman region, Iran," *Journal of African Earth Sciences*, vol. 128, pp. 116-126, 2017, doi: 10.1016/j.jafrearsci.2016.11.032.
- [9] R. Shamsi, H. Dehghani, M. Jalali, and B. Jodeiri Shokri, "Ore grade estimation using the imperialist competitive algorithm (ICA)," *Arabian Journal of Geosciences*, vol. 14, no. 14, 2021, doi: 10.1007/s12517-021-07808-7.
- [10] A. Skabar, "Modeling the Spatial Distribution of Mineral Deposits Using Neural Networks," *Natural Resource Modeling*, vol. 20, no. 3, pp. 435-450, 2008, doi: 10.1111/j.1939-7445.2007.tb00215.x.
- [11] R. Zuo and E. J. M. Carranza, "Support vector machine: A tool for mapping mineral prospectivity," *Computers & Geosciences*, vol. 37, no. 12, pp. 1967-1975, 2011, doi: 10.1016/j.cageo.2010.09.014.
- [12] T. B. Afeni, A. I. Lawal, and R. A. Adeyemi, "Re-examination of Itakpe iron ore deposit for reserve estimation using geostatistics and artificial neural network techniques," *Arabian Journal of Geosciences*, vol. 13, no. 14, 2020, doi: 10.1007/s12517-020-05644-9.
- [13] B. Jafarsteh, N. Fathianpour, and A. Suárez, "Comparison of machine learning methods for copper ore grade estimation," *Computational Geosciences*, vol. 22, no. 5, pp. 1371-1388, 2018, doi: 10.1007/s10596-018-9758-0.
- [14] A. D. Goswami, M. K. Mishra, and D. Patra, "Evaluation of machine learning algorithms for grade estimation using GRNN & SVR," *Engineering Research Express*, vol. 4, no. 3, 2022, doi: 10.1088/2631-8695/ac8912.
- [15] M. M. Zaki et al., "A Novel Approach for Resource Estimation of Highly Skewed Gold Using Machine Learning Algorithms," *Minerals*, vol. 12, no. 7, 2022, doi: 10.3390/min12070900.
- [16] S. Dutta, S. Bandopadhyay, R. Ganguli, and D. Misra, "Machine Learning Algorithms and Their Application to Ore Reserve Estimation of Sparse and Imprecise Data," *Journal of Intelligent Learning Systems and Applications*, vol. 02, no. 02, pp. 86-96, 2010, doi: 10.4236/jilsa.2010.22012.
- [17] S. Soltani-Mohammadi, F. S. Hoseinian, M. Abbaszadeh, and M. Khodadadzadeh, "Grade estimation using a hybrid method of back-propagation artificial neural network and particle swarm optimization with integrated samples

- coordinate and local variability," *Computers & Geosciences*, vol. 159, 2022, doi: 10.1016/j.cageo.2021.104981.
- [18] R. K. Singh, D. Ray, and B. C. Sarkar, "Mineral deposit grade assessment using a hybrid model of kriging and generalized regression neural network," *Neural Computing and Applications*, vol. 34, no. 13, pp. 10611-10627, 2022, doi: 10.1007/s00521-022-06951-w.
- [19] Y. Zhang, S. Song, K. You, X. Zhang, and C. Wu, "Relevance vector machines using weighted expected squared distance for ore grade estimation with incomplete data," *International Journal of Machine Learning and Cybernetics*, vol. 8, no. 5, pp. 1655-1666, 2016, doi: 10.1007/s13042-016-0535-x.
- [20] M. A. Mahboob, T. Celik, and B. Genc, "Review of machine learning-based Mineral Resource estimation," *Journal of the Southern African Institute of Mining and Metallurgy*, vol. 122, no. 11, pp. 1-10, 2023, doi: 10.17159/2411-9717/1250/2022.
- [21] F. Atalay, "Estimation of Fe Grade at an Ore Deposit Using Extreme Gradient Boosting Trees (XGBoost)," *Mining, Metallurgy & Exploration*, pp. 1-10, 2024.
- [22] M. Galetakis, A. Vasileiou, A. Rogdaki, V. Deligiorgis, and S. Raka, "Estimation of Mineral Resources with Machine Learning Techniques," presented at the International Conference on Raw Materials and Circular Economy, 2022.
- [23] X.-l. Li, Y.-l. Xie, Q.-j. Guo, and L.-h. Li, "Adaptive ore grade estimation method for the mineral deposit evaluation," *Mathematical and Computer Modelling*, vol. 52, no. 11-12, pp. 1947-1956, 2010, doi: 10.1016/j.mcm.2010.04.018.
- [24] F. Maepa, R. S. Smith, and A. Tessema, "Support vector machine and artificial neural network modelling of orogenic gold prospectivity mapping in the Swayze greenstone belt, Ontario, Canada," *Ore Geology Reviews*, vol. 130, 2021, doi: 10.1016/j.oregeorev.2020.103968.
- [25] N. Mery and D. Marcotte, "Quantifying Mineral Resources and Their Uncertainty Using Two Existing Machine Learning Methods," *Mathematical Geosciences*, vol. 54, no. 2, pp. 363-387, 2021, doi: 10.1007/s11004-021-09971-9.
- [26] B. Samanta, R. Ganguli, and S. Bandopadhyay, "Comparing the predictive performance of neural networks with ordinary kriging in a bauxite deposit," *Mining Technology*, vol. 114, no. 3, pp. 129-139, 2013, doi: 10.1179/037178405x53980.
- [27] K. Mostafaei, S. maleki, and B. Jodeiri, "A new gold grade estimation approach by using support vector machine (SVM) and back propagation neural network (BPNN)- A Case study: Dalli deposit, Iran," 2022, doi: 10.21203/rs.3.rs-2008568/v1.
- [28] N. B. Tsae, T. Adachi, and Y. Kawamura, "Application of Artificial Neural Network for the Prediction of Copper Ore Grade," *Minerals*, vol. 13, no. 5, 2023, doi: 10.3390/min13050658.
- [29] X. Zhang, S. Song, J. Li, and C. Wu, "Robust LS-SVM regression for ore grade estimation in a seafloor hydrothermal sulphide deposit," *Acta Oceanologica Sinica*, vol. 32, no. 8, pp. 16-25, 2013, doi: 10.1007/s13131-013-0337-x.
- [30] A. G. Journel and C. J. Huijbregts, "Mining geostatistics," 1976.
- [31] T. Hossen, S. J. Plathottam, R. K. Angamuthu, P. Ranganathan, and H. Salehfar, "Short-term load forecasting using deep neural networks (DNN)," in *2017 North American Power Symposium (NAPS)*, 2017: IEEE, pp. 1-6.
- [32] A. L. Maas et al., "Building DNN acoustic models for large vocabulary speech recognition," *Computer Speech & Language*, vol. 41, pp. 195-213, 2017.
- [33] S. Wang, F. Shui, T. Stratford, J. Su, and B. Li, "Modelling nonlinear shear creep behaviour of a structural adhesive using deep neural networks (DNN)," *Construction and Building Materials*, vol. 414, p. 135083, 2024.
- [34] W. Samek, G. Montavon, S. Lapuschkin, C. J. Anders, and K.-R. Müller, "Explaining deep neural networks and beyond: A review of methods and applications," *Proceedings of the IEEE*, vol. 109, no. 3, pp. 247-278, 2021.
- [35] A. J. Smola and B. Schölkopf, "A tutorial on support vector regression," *Statistics and computing*, vol. 14, pp. 199-222, 2004.
- [36] H. Drucker, C. J. Burges, L. Kaufman, A. Smola, and V. Vapnik, "Support vector regression machines," *Advances in neural information processing systems*, vol. 9, 1996.
- [37] T. Chen, "Xgboost: extreme gradient boosting," *R package version 0.4-2*, vol. 1, no. 4, 2015.