

Derleme / Review

## Maden Potansiyeli Tahmin Yöntemlerine Genel Bir Bakış *A Review of Mineral Potential Estimation Methods*

Yusuf Ziya ÖZKAN 

DAMA Mühendislik A.Ş., Ankaralılar Cad. Azatbey Sit. 2562.Sok. No:1/14-A Çayyolu 06810 Ankara

Geliş (Received): 04/02/2025 / Düzeltme (Revised): 28/03/2025 / Kabul (Accepted): 11/04/2025

### ÖZ

Maden bulunabilirlik analizleri, maden aramalarını buluş şansı en yüksek sahalara yönlendirerek başarı oranını artırır ve maliyetleri düşürür. Geleneksel analizlerin öznelliği, 1960'lerden itibaren istatistiksel yöntemlerin kullanımıyla aşılmıştır. 1980'lerde Coğrafi Bilgi Sistemleri (CBS) teknolojisinin gelişimi, 2000'lerde makine öğrenimi ve veri bilimi yenilikleri, süreci daha nesnel ve etkili hâle getirmiştir. Bu analizler, bilgi odaklı ve veri odaklı olmak üzere iki ana yöntemle gerçekleştirilir. Bilgi odaklı sistemler, uzman görüşlerini taklit ederek yatak modeli veya mineral sistem yaklaşımlarına dayanır. Kanıt ağırlıkları yöntemi, bu sistemlerin en yaygın kullanılanıdır. CBS ile yer bilimi verileri birleştirilerek pozitif ve negatif ağırlıklar hesaplanır. Bayes teoremi kullanılarak olasılıklar güncellenir. ÇÖKA (Çok Ölçütlü Karar Verme Analizi), Bulanık Mantık gibi yöntemler de bilgi odaklı yaklaşımlar arasında yer alır. Veri odaklı yöntemler, belirli bir model veya hipotez olmadan doğrudan verilerden öğrenir. İstatistiksel yöntemlerin (örneğin lojistik regresyon analizi) yanı sıra, makine öğrenimi algoritmaları (destek vektör makineleri, yapay sinir ağları, karar ağaçları) karmaşık veri setlerindeki örüntüleri belirlemede güçlüdür. Bu yöntemler, arama süreçlerini daha sistematik ve nesnel tahmine dayalı hâle getirir. Ancak, başarıları veri kalitesine ve seçilen modellerin etkinliğine bağlıdır. Bu nedenle, doğru verilerin toplanması ve analiz süreçlerinin optimize edilmesi büyük önem taşır.

**Anahtar Kelimeler:** Maden Bulunabilirlik Analizi, Bilgi Odaklı Yöntemler, Veri odaklı yöntemler, Kanıt Ağırlıkları, AHP, Lojistik Regresyon Analizi, Makine Öğrenimi, Coğrafi Bilgi Sistemleri (CBS).

### ABSTRACT

Mining prospectivity analyses enhance success rates and reduce costs by directing exploration efforts toward areas with the highest discovery potential. The subjectivity of traditional analysis has been addressed since the 1960s through the use of statistical techniques. The development of geographic information systems (GIS) technology in the 1980s and advancements in machine learning and data science in the 2000s have made the process more objective and effective. These analyses are conducted using two main approaches: knowledge-driven and data-driven methods. Knowledge-driven systems mimic expert reasoning and rely on deposit models or mineral system approaches. The weight-of-evidence method is the most commonly used among these systems. GIS is used to integrate geoscientific data, to calculate positive and negative weights, and to update probabilities using Bayes' theorem. Other knowledge-driven approaches include analytic hierarchy process (AHP) and fuzzy logic. Data-driven systems learn directly from data without relying on predefined models or hypotheses. In addition to statistical methods (e.g., logistic regression analysis), machine learning algorithms—such as support vector machines, artificial neural networks, and decision trees—are highly effective in identifying patterns within complex datasets. These methods make exploration

*processes more systematic and predictive. However, their success depends on data quality and the effectiveness of the selected models. Therefore, collecting accurate data and optimizing analytical processes have great importance.*

**Keywords:** Mineral prospectivity analysis, knowledge-driven approaches, data-driven approaches, weight of evidence, AHP, logistic regression analysis, machine learning, geographic information systems (GIS).

## TANIMI VE TARİHSEL GELİŞİMİ

Maden bulunabilirlik (mineral prospectivity) analizi, genellikle bölgesel ölçekte (genellikle  $\geq 100 \text{ km}^2$ ) ya da kamp ölçeğinde (genellikle  $\geq 25 \text{ km}^2$ ) arama hedeflemesi için kullanılan bir tahmin aracıdır (Carranza, 2021). Proje ölçeği veya maden yatağı ölçeğinde, doğrudan algılama tekniklerine kıyasla daha az etkili olduğundan dolayı daha az tercih edilir (McCuaig ve Hronsky, 2000; Hronsky ve Groves, 2008; McCuaig vd., 2010).

Maden bulunabilirliği terimi, “maden potansiyeli” (mineral potential), “maden oluşumuna elverişlilik” (mineral favourability) ve arama potansiyeli (exploration potential) terimleriyle benzer anlam taşır. Bu nedenle, “maden bulunurluğu”, “maden potansiyeli”, “maden elverişliliği” ve “arama potansiyeli” terimleri eş anlamlıdır ve birbirinin yerine kullanılabilir. Kavramın aranan türde maden yataklarının muhtemelen var olduğu uygun alanları tahmin etmeye yönelik anlamını vurgulamak amacıyla bu çalışmada “maden bulunabilirliği” terimi tercih edilmiştir.

Bu analizlerin temel amacı, aranan tipte maden yataklarının bulunma şansının yüksek olduğu alanları (prospects) belirlemek ya da öngörmektir. Bu sayede arama çalışmaları, aranan türde bir maden yatağının bulunma olasılığının yüksek olduğu dar alanlara odaklandırılarak zaman ve maliyet açısından daha verimli hale getirilebilir (Hronsky ve Kreuzer, 2019). Bu yönüyle söz konusu analizler, maden arama projelerinin optimizasyon sürecinin bir parçası

olarak değerlendirilebilir (Özkan, 2023, 2024). Nitekim yanlış saha seçimleri, sonraki arama aşamalarının anlamını büyük ölçüde yitirmesine neden olabilir. Mevlana'nın ifadesiyle, “Bir şeyi bulunmadığı yerde aramak, aramamak demektir.”

Maden bulunabilirlik analizleri arama hedeflemesi yanı sıra bölgenin genel maden potansiyelini tahmin etme ve arazinin madencilik dışında kullanımları için fırsat maliyetlerini değerlendirme amacıyla da kullanılabilir (Drew, 1993). Bölgesel analizler, özellikle kritik ve stratejik madenlerin ulusal ve küresel hammadde güvenliği ile arazi kullanım planlamalarında da önemli bir role sahiptir.

Maden bulunabilirlik analizleri genellikle MTA benzeri jeolojik araştırma kurumlarından ve eğer ulaşılabilir ise önceki arama projelerinden sağlanan verilere dayanarak gerçekleştirilir. Bazen bu mevcut verileri desteklemek üzere uzaktan algılama yöntemleriyle alterasyon, kaya türü, çizgisellikler gibi bazı ek veriler de toplanabilir. Bu sınırlı ve büyük oranda dolaylı verilere dayanarak, bir arazide istenen türde bir yatağının olup olmadığını kesinlikle belirleme imkânsızdır. Bunun en önemli nedeni, yeraltındaki bir maden yatağı ile ilişkili olduğu düşünülen dolaylı kanıtların (örneğin alterasyonlar, jeokimyasal veya jeofiziksel anomaliler) gerçekte başka doğal süreçler veya insan kaynaklı süreçlerle ilişkili olabilmeleridir. Dolayısıyla bu verilerle maden yataklarının varlığını öngörme süreci deterministik değil, stokastiktir.

## Geleneksel Yaklaşım

Maden bulunabilirlik analizinde hala yaygın olarak uygulanan geleneksel yaklaşım mevcut jeolojik, jeokimyasal ve jeofizik verilerin kişisel deneyim ve yorumlamasına dayanır (Porwal ve Kreuzer, 2010). Bu yolla belirlenen umut vaat eden alanlar (prospects) jeolojik haritalarda kutular veya dairelerle gösterilir.

Geleneksel yöntemde, aynı bölgeye ait farklı türde yerbilim verilerini içeren haritalar ya uzmanın zihninde ya da ışıklı masa kullanılarak üst üste yerleştirilerek birlikte yorumlanmaya çalışılırdı. Ancak, ikiden fazla harita üst üste konulduğunda haritaları okumak genellikle mümkün olmazdı. Ayrıca, farklı ölçeklerdeki haritaların mekanik yollarla (pantograf ile) büyütülerek veya küçültülerek çakıştırılması da oldukça zordu. Bu nedenle, farklı haritaları birleştirerek sahanın bütüncül bir görünümünü elde etmek çoğu zaman imkânsız hale gelirdi.

Geleneksel yaklaşım, genellikle hedeflenen maden yatağı tipi için kavramsal yatak modellerine, geçmiş keşif verileri (varsa) ve hedeflenen maden kuşağında veya başka benzer jeolojik kuşaklarda bulunan benzer tipteki bilinen maden yataklarının jeolojik özellikleri tarafından yönlendirilir. Uzmanlık bilgi ve tecrübesinden yararlanması sayesinde verimlidir. Ancak öznellik ve önyargı içerdiği için şeffaflık ve tekrarlanabilirlikten yoksundur. Ayrıca, bu yaklaşım, genellikle yatak ölçeğinde formüle edilen ve bu nedenle geniş bölgesel ya da kamp ölçeğinde daha az etkili olabilen maden yatak modelleri tarafından yönlendirilir (McCuaig vd., 2014).

## İstatistiksel Öngörü Modellerinin Kullanımı

1960'ların sonlarına doğru çoğunlukla ABD ve Kanada'dan matematiksel odaklı jeologlardan oluşan bir grup ((örneğin, Harris, 1965, 1969,

Sinclair ve Woodsworth, 1970, Agterberg, 1971, 1973, 1974, Singer, 1972), öznellikten kaynaklanan bu sorunları aşmak amacıyla maden bulunabilirlik analizi için farklı istatistiksel modellerin kullanımını araştırmaya başladı. Ana hedefleri, geleneksel yaklaşıma kıyasla nesnel ve tekrarlanabilir yöntemler bulmaktır.

Bu teknikler, belirli bir kuşakta, iyi keşfedilmiş alanlardaki (kontrol bölgeleri) bilinen maden yatakları ile jeolojik özellikler arasındaki mekânsal ilişkiyi veri odaklı regresyon modeli ile analiz etmeyi ve bu modelleri, kuşağın daha az aranmış veya hiç aranmamış bölümlerinde hedeflenen yatakların meydana gelme olasılığını belirlemek için uygulamayı içeriyordu.

## CBS Tabanlı Yöntemlere Geçiş

1980'lerin sonlarında ticari coğrafi bilgi sistemlerinin (CBS) ortaya çıkışı, maden bulunabilirlik analizinde istatistiksel modelleme tekniklerinin etkinliğini artırarak bu alanda büyük bir gelişim dalgasını tetiklemiştir. CBS tabanlı maden bulunabilirlik analizi, belirli bir bölgedeki maden potansiyelini değerlendirmek ve hedef maden yataklarının bulunabilme şansı yüksek alanları tespit etmek için mekânsal analiz tekniklerinin sistematik bir şekilde uygulanmasını içerir. Bu yöntemler, ilgili verilerin toplanması, bütünleştirilmesi ve analiz edilmesi yoluyla maden yataklarının bulunmasına yönelik karar destek süreçlerini güçlendirmektedir.

Hangi verilerin mineralizasyon ile ilgili olduğu, dolayısıyla hangi verilerin modele dahil edileceği, arama modeline göre belirlenir. Arama modelleri, maden yataklarının oluşumu ile bunları işaret eden jeolojik, jeokimyasal veya jeofizik göstergeler arasında nedensellik ya da birliktelik ilişkisi kuran teorik ve/veya ampirik

açıklamalıdır. Bu modeller iki temel yaklaşıma dayanır:

- a) Maden Yatağı Modeli Temelli Yaklaşım (Model Odaklı Yaklaşım): Bu yaklaşım, belirli bir maden yatağı türünün tanımlayıcı özelliklerini sistematik olarak açıklar (Cox vd., 1986). ABD Jeoloji Araştırmaları Kurumu'nun (USGS) yayımladığı "Mineral Deposit Models" serisi, 100'den fazla maden yatağı türünü betimleyici, genetik, tenör - tonaj ile yatak yoğunluğu modelleri üzerinden tanımlar (Singer, 1972; Cox ve Singer, 1986; Mosier ve Page, 1988; Bliss, 1992; Singer vd., 2009; Mosier vd., 2009).
- b) Mineral Sistem Temelli Yaklaşım (Süreç Odaklı Yaklaşım): 1990'larda ortaya çıkan bu yaklaşım, maden yataklarının özelliklerinden ziyade, onları oluşturan jeolojik süreçlere odaklanır (Wyborn vd., 1994; Knox-Robinson ve Wyborn, 1997; Kreuzer vd., 2008; McCuaig ve Hronsky, 2005; McCuaig vd., 2010). Bu süreçler; metallerin kaynağı, taşınması, kapan mekanizmaları gibi faktörler ve bunların jeolojik kayıtlardaki izleri ile tanımlanır (Hronsky ve Groves, 2008; Pirajno, 2009; Porwal vd., 2010; Hronsky ve Kreuzer, 2019).

Modelleme sürecinde kullanılan farklı veri setleri (litoloji, yapısal jeoloji, manyetik anomali haritaları vb.), CBS ortamında işlenebilir hale getirilir. Bu süreç, sayısallaştırma, uygun datum ve projeksiyon sistemine dönüştürme ve veri formatlarının uyumlu hale getirilmesini içerir.

### **CBS TABANLI MADEN BULUNABİLİRLİK ANALİZ YÖNTEMLERİ**

Son 30-35 yılda, CBS kullanılarak maden bulunabilirlik haritaları üretmek için birçok

yenilikçi yöntem geliştirilmiştir. Bu yöntemlerin kullanımı, Bonham-Carter (1994), Pan ve Harris (2000) ile Carranza (2008) gibi önemli eserlerle hız kazanmış ve 2000'li yıllarda küresel ölçekte yaygın bir uygulama alanı bulmuştur. Ancak, bu yöntemlere dair Türkiye'de sınırlı bir literatür olduğu dikkat çekmektedir. Özkan (2004 ve 2023) dışında, bu alanda Türkiye'de yayımlanmış başka bir çalışmaya rastlanılmamıştır. Bu durum, Türkiye'de maden bulunabilirlik analizlerinde CBS tabanlı yöntemlerin yeterince anlaşılmadığını ve konunun daha fazla tartışılmaya ihtiyaç duyduğunu göstermektedir. Bu yazı, bu ilgisizliğe dikkat çekmek ve farkındalığı artırmak amacıyla kaleme alınmıştır.

CBS tabanlı maden bulunabilirlik analizi yöntemleri, iki temel sınıfa ayrılmaktadır (Bonham-Carter, 1994; Carranza, 2009'a, b; Harris vd., 2015):

1. Bilgi odaklı yöntemler
2. Veri odaklı yöntemler.

### **Bilgi Odaklı Yöntemler**

Bilgiye dayalı (knowledge-driven) maden potansiyeli (prospectivity) analiz yöntemleri, uzman görüşleri, teorik bilgi ve literatürden elde edilen çıkarımlara dayanarak uygun bölgelerin belirlenmesine yönelik yaklaşımlardır. Bu yöntemler, genellikle jeolojik modeller, maden yataklarının oluşum mekanizmaları ve belirli bir maden türüne ait anahtar göstergelerin (örneğin jeokimyasal anomaliler, yapısal kontrol, mineral zonları) sistematik analizi üzerine odaklanırlar.

Bu yöntemlerde veriler uzman görüşlerine dayalı ağırlıklandırmalarla değerlendirilir. Belirli bir maden yatağı türünün oluşumunu kontrol eden faktörler iyi bilindiğinde, bu bilgi belirli göstergelere ağırlık vererek analiz yapılmasını sağlar.

İlk bilgi odaklı modelleme yöntemlerinden biri, 1970'lerin sonunda Stanford Araştırma Enstitüsü'nde özellikle porfiri bakır yataklarının keşfine yönelik olarak geliştirilen ve uzman sistem yaklaşımıyla çalışan "Prospector" yazılımıdır (Duda vd., 1978). Bu yazılım, bu tür yöntemlerin temelini oluşturmuştur. Günümüzdeki bilgi odaklı yöntemlerin pek çoğu, benzer bir mantığı daha gelişmiş CBS araçları ve daha karmaşık analiz yöntemleriyle uygulamaktadır.

Prospector, jeolojik süreçler ve maden oluşum mekanizmaları hakkında uzmanlardan elde edilen bilgileri kural tabanlı bir sistemde bir araya getirerek analiz yapmıştır. Bu sistem, belirli bir bölgenin maden potansiyelini değerlendirmek için belirli göstergelere (örneğin, jeokimyasal anomaliler, yapısal özellikler) dayalı olarak çalışıyordu.

Daha sonra 1990'ların başında birçok bilgi odaklı yöntem geliştirilmiştir. Örneğin, bulanık mantık (An vd., 1991), ikili çakıştırma (binary index overlay) ve Bool Mantığı (Bonham-Carter, 1994), inanç modelleri (Carranza, 2008).

Bu yöntemler, jeolojik haritalar, jeofizik ve jeokimyasal verilerle bütünleştirilerek potansiyel arama alanlarının belirlenmesine olanak tanır.

Bilgi odaklı yöntemlerin başarısı, uzmanlık düzeyine ve kullanılan modelin doğruluğuna bağlıdır. Örneğin, hangi ölçütlerin dikkate alınacağı ve bu ölçütlere ne ağırlık verileceği, uzmanların bilgi ve tercihlerine dayandığından, öznellik ve yanlılık riski taşır (Harris vd., 2015). Ayrıca, bu yöntemler yalnızca önceden bilinen kanıtlarla ilişkilendirilmiş yataklara yönelik analiz yapabilir; bilinmeyen yatak türlerinin keşfi mümkün değildir.

Bilgiye dayalı yaklaşımlar, özellikle veri yetersizliğinin olduğu, az araştırılmış bölgelerde hızlı ve maliyet-etkin bir analiz yapmak için

etkili bir araç olarak kabul edilmektedir (Harris vd., 2015).

### Veri Odaklı Yöntemler

Veriye dayalı (data-driven) yöntemler, mineralizasyonu etkileyen faktörlerin önceden bilinmesine ihtiyaç duymaz. Bu yöntemlerde kullanılan algoritmalar, verilerdeki ilişkileri otomatik olarak öğrenir. Bu, veriye dayalı yöntemlere, bilgi odaklı yöntemlere göre daha nesnellik kazandırır. Ancak bu tam anlamıyla nesnellik değildir. Çünkü bu yöntemlerde de algoritmanın hangi verileri kullanacağını, nasıl analiz yapacağını ve sonuçların nasıl yorumlanacağını yer bilimcilerin bilgi ve sezgileri şekillendirir.

Veri odaklı yöntemlerin doğru sonuçlar elde edilebilmesi için yeterli miktarda ve doğru mineralizasyon verisi içeren bir eğitim setine ihtiyaç vardır. Eksik veya hatalı veri setleri, sonuçların güvenilirliğini ciddi şekilde etkileyebilir. Bu nedenle, veriye dayalı yöntemler genellikle iyi araştırılmış ya da çok sayıda bilinen maden yatağına sahip bölgeler için uygundur (Zhang ve Zhou, 2015; Zuo, 2020).

İlk veri odaklı yöntem, «kanıt ağırlıkları» modeli, 1980'lerin sonlarında geliştirilmiştir. Günümüzde çok sayıda veri odaklı yöntem bulunmaktadır. Bunlar iki ana gruba ayrılır:

- a) **Denetimli Öğrenme (Supervised Learning):** Bu yöntemlerde bağımlı değişken (maden yatağı) var/yok etiketlidir. Eğitim veri kümesinde maden yataklarının bulunduğu ve bulunmadığı bölgeler belirtilir. Yaygın olarak kullanılan algoritmalar: Lojistik regresyon, Karar ağaçları (Ferri vd., 2003), Rastgele ormanlar (Carranza ve Laborte, 2015), Destek vektör makineleri (Abedi vd., 2012), Yapay sinir ağları (Harris ve Pan, 1999).

**b) Denetimsiz Öğrenme (Unsupervised Learning):** Bağımlı değişkenin bulunmadığı veri setlerinde kullanılır. Bu yöntemler, bağımsız değişkenler arasındaki örüntüleri, kümelenmeleri veya anomalileri tespit etmeye odaklanır. Örnek algoritmalar: Kanıt ağırlıkları yöntemi (Bonham-Carter vd., 1989), Yapay sinir ağları (Brown vd., 2000).

### Karma Yöntemler

Bilgi odaklı ve veri odaklı yöntemlerin birbirini dışladığı düşünülse de her iki yöntemin güçlü yönlerini birleştirmek amacıyla bulanık kanıt ağırlıkları (Cheng ve Agterberg, 1999) ve nöro-bulanık modeller (Porwal vd., 2004) gibi karma veya melez yöntemler geliştirilmiştir. Karma yöntemler birbirlerinin eksik yanlarını tamamlamayı amaçlar (Porwal ve Kreuzer, 2010).

En iyi yöntem ya da her duruma uyan tek bir çözüm yoktur. Yöntemlerin üstün yanlarını ve sınırlamalarını dikkate alarak duruma uygun yöntemi seçmek gerekir. Bu seçime yardımcı olmak amacıyla makalenin sonraki bölümlerinde farklı modelleme tekniklerini, temel ilkeleri, güçlü ve zayıf yönleri hakkında bir fikir vermek üzere bilgi odaklı yöntemlere örnek olarak analitik hiyerarşi süreci yöntemi, veri odaklı yöntemlerden kanıt ağırlıkları ve lojistik regresyon yöntemi ele alınacak, makine öğrenimi yöntemlerine kısaca değinilecektir.

### KANIT-AĞIRLIKLARI YÖNTEMİ

1980'lerin sonlarında, F.P. Agterberg, G.F. Bonham-Carter ve çalışma arkadaşları, daha önce tıbbi teşhis için geliştirilmiş olan Bayes kanıt ağırlıkları (weights-of-evidence) modelini CBS ortamında maden bulunabilirlik analizi

için uygulamışlardır (Bonham-Carter vd., 1989). Eksik veri kümelerini barındırabilmesi, sezgisel, nesnel, uygulanması ve yorumlanmasının kolay olması nedeniyle kanıt ağırlıkları modeli, maden bulunabilirlik analizinde en yaygın kullanılan matematiksel modellerden biri olmuştur ve olmaya devam etmektedir (Porwal ve Kreuzer, 2010). Ancak, bu model, girdi veri kümeleri güçlü bir şekilde korelasyonluysa yanlış sonuçlar üretebilir (örn. Porwal vd., 2006).

Kanıt ağırlıkları (weights of evidence) yöntemi, maden potansiyeli haritalaması için yaygın olarak kullanılan veri odaklı bir yaklaşımdır. İlk olarak Bonham-Carter vd. (1989) tarafından maden potansiyeli tahmini için uygulanmıştır.

Bu yöntemin temel girdisi, çalışma alanındaki bilinen maden yataklarının konumudur. "Eğitim verisi" olarak adlandırılan bu veri seti, modelin temelini oluşturur. Yöntem, istatistiksel yöntemlerle bireysel kanıt katmanlarının göreceli önemini tahmin edebilir ve bir maden yatağı veri setine ve bir dizi jeolojik özelliğe ihtiyaç duyarak bir maden potansiyel haritası oluşturabilir (Bonham-Carter vd. (1989; Porwal ve Hale, 2000).

Klasik kanıt ağırlıkları yöntemi ile 2B CBS tabanlı maden bulunabilirlik haritası üretim süreci aşağıdaki adımlar izlenerek uygulanır (Bonham-Carter vd. (1989; Porwal ve Hale, 2000):

### Veri Hazırlığı

Veri hazırlığı ilgili kanıt haritalarını (örneğin, jeoloji, eğim, fay haritaları vb.) aynı koordinat sisteminde birleştirerek ve raster formata çevirerek başlar. Raster harita, belirli boyutta eşit hücrelere (piksel) bölünmüş bir harita anlamına gelir (Şekil 1). CBS'de bir haritayı ızgara


yapısına bölerek, mekânsal ilişkileri analiz etmek mümkün hale gelir. Tüm raster katmanlar, aynı çözünürlükte ve aynı hücre boyutunda olmalıdır. Her hücre, genellikle tek bir değeri temsil eder ve bu değer, kaya türü, alterasyon tipi, manyetik anomali veya bir jeokimyasal ölçüm gibi mekânsal bir özelliği ifade eder.

Hücre (piksel) boyutu, maden yatağı bulunma olasılığı tahminlerini doğrudan etkiler. Çok büyük hücreler (düşük çözünürlük) genelleştirmeye (küçük ölçekli jeolojik ayrıntıların kaybolmasına), çok küçük hücreler ise aşırı hassasiyete neden olabilir. Bu nedenle, jeolojik bağlam (örn. maden yataklarının tipik boyutları), veri çözünürlüğü ve analiz ölçeğine göre optimum bir hücre boyutu seçmek gerekir. Örneğin bölgesel analizler için 100–500 m hücre boyutu kullanılabilirken, yerel analizler için 10–50 m piksel boyutu daha uygun olabilir.

### Kategorik Değişkenler

Kategorik değişkenler (örneğin, farklı litoloji veya alterasyon türlerini temsil eden bir jeoloji haritası) genellikle poligonlar şeklinde gösterilir. Bu poligonlar raster hücrelere atanırken her hücrenin poligon sınıflarıyla örtüşen alanı hesaplanır ve en büyük alanı kaplayan kategori hücreye atanır (Şekil 1).

Maden potansiyeli haritalamasında kanıt ağırlığı yöntemine yönelik yaygın eleştirilerden biri koşullu bağımsızlık sorunudur (Agterberg ve Cheng, 2002). Bu yöntemde önemli bir varsayım, modeldeki tüm kanıt katmanlarının maden oluşumuna karşı koşullu olarak bağımsız olmasıdır. Aksi takdirde, bu durum ardıl olasılık sapmalarına ve tahminlerin güvenilirliğine yol açar. Bu varsayımı sağlamak amacıyla, kanıt katmanlarının koşullu bağımsızlığını doğrulamak için test yapılır ve problem yaratabilecek veriler çalışmada kullanılmaz.



Şekil 1: Çok sınıflı bir haritanın raster haritaya dönüştürülmesi. Bu sayısal matriste örneğin D1: Kumtaşı, D2: Marn, D3: kireçtaşı, D4: Çamurtaşı birimlerini temsil edebilir.

Figure 1: Conversion of a multi-class map into a raster map. In this numerical matrix, for example, D1 may represent sandstone, D2 marl, D3 limestone, and D4 mudstone units.

### Kanıt Katmanlarının Bütünleştirilmesi

Farklı kanıt katmanları ortak bir mekânsal veri tabanında bütünleştirilir. Her bir hücre, kanıt katmanlarından alınan değerlere göre tanımlanır (örneğin, bir hücrenin eğim sınıfı ve jeoloji tipi belirtilir).

### Mekânsal Analiz (Kanıt Ağırlıklarının Hesaplanması)

Arama modeline göre seçilen bağımsız ya da öngörücü değişkenlerle hedef mineralizasyon arasındaki mekânsal ilişkiler (korelasyon) nicel olarak analiz edilir. Bu işlem, öngörücü değişkenlerin türüne göre şu şekilde yapılır:

#### a) Kategorik değişkenlerin mekânsal analizi

Bir mekânsal değişkenin (örneğin bir kaya veya alterasyon türünün) belirli bir mineralizasyon ile ilişkisini ölçmek için genellikle frekans oranı (FO) kullanılır. Frekans oranı şu formülle hesaplanır:

$$FO = \left( \frac{N_m / \sum N_m}{N / \sum N} \right) \quad (1)$$

Bu ifadede pay, belirli bir kanıt sınıfında (örneğin bir kaya türü) mineralizasyon gözlemlenen hücrelerin, toplam mineralize hücrelere oranını ifade eder. Analiz edilen kanıt sınıfında mineralizasyon görülme sıklığını (gözlenen sıklık oranını) gösterir. Payda ( $N / \sum N$ ), belirli bir kanıt sınıfına sahip olan hücrelerin toplam hücrelere oranıdır. Bu, maden yataklarının rastgele dağılımı halinde kanıt sınıfının içermesi beklenen sıklık oranını ifade eder. Buna göre frekans oranı, mineralizasyonun kanıt sınıfında gözlenme oranının beklenen orana oranı olarak tanımlanabilir.

Frekans Oranı, kanıt sınıfının mineralizasyon üzerindeki etkisinin rastgele bir dağılıma göre ne kadar güçlü olduğunu ölçer:

- Eğer  $FO > 1$  ise, mineralizasyonun bu kanıt sınıfı içinde oransal olarak daha yoğun bulunduğunu gösterir.

Bu kanıt sınıfı mineralizasyonla ilişkili kabul edilir ve bunu içeren hücrelere “1” değeri atanır.

- Eğer  $FO < 1$  ise, bu kanıt sınıfının mineralizasyon ile zayıf bir ilişki gösterdiği anlamına gelir. Bu kanıt sınıfı mineralizasyonla ilişkisiz kabul edilir ve bunu içeren hücrelere “0” atanır).

Bu analizlerin sonucunda, mineralizasyon ile pozitif mekânsal ilişkiye sahip kategorik değişkenlerin görüldüğü hücreler “1”, diğer tüm hücreler “0” olarak yeniden sınıflandırılır. Böylece her kategorik sınıf için ayrı bir ikili harita oluşturulur (Şekil 2b).

Eğer yeterli sayısal veri bulunmuyorsa, uzman bilgisine dayalı yaklaşımlar da kullanılabilir. Örneğin, belirli bir alterasyon türü (örneğin, potasik alterasyon) jeolojik literatür veya saha gözlemleri temelinde mineralizasyon için önemli kabul ediliyorsa, bu alterasyon türü mineralizasyonla ilişkili olarak değerlendirilir ve “1” atanır.

Örneğin Şekil 1’deki raster haritadaki verilere göre, her kanıt sınıfı için toplam hücre sayısını ( $N$ ), mineralizasyon içeren hücre sayısını ( $N_m$ ), ve mineralizasyon içermeyen hücre sayısı Çizelge 1’de verilmiştir.

#### b) Sürekli değişkenlerin mekânsal analizi

Sürekli değişkenler (örneğin, jeokimyasal element konsantrasyonları, manyetik anomaliler, radyometrik ölçümler), belirli bir eşik değer (threshold value) kullanılarak ikili haritalara dönüştürülür. Bu işlem şu şekilde gerçekleştirilir:

Çizelge 1. Şekil 1'deki haritadan türetilen toplam hücre sayısı (N), mineralize hücre sayısı (Nm) ve mineralize olmayan hücrelerin özeti.

Table 1. Summary of total cells (N), mineralized cells (Nm), and non-mineralized cells derived from the map in Figure 1.

| Kanıt Sınıfı | Toplam Hücre Sayısı (N) | Mineralizasyonlu Hücre (Nm) | Mineralizasyonlu Olmayan Hücre (N-Nm) |
|--------------|-------------------------|-----------------------------|---------------------------------------|
| 1            | 25                      | 6                           | 19                                    |
| 2            | 36                      | 5                           | 31                                    |
| 3            | 6                       | 1                           | 5                                     |
| 4            | 33                      | 1                           | 32                                    |
| Toplam       | 100                     | 13                          | 87                                    |

- Eşik değerini aşan hücreler “ilişkili” kabul edilerek 1 ile kodlanır.
- Eşik değerinin altında kalan hücreler “ilişkisiz” kabul edilerek 0 ile kodlanır.

Eşik değerleri, genellikle mineralizasyon ile en güçlü ilişkiye sahip olan sınıfları belirlemek amacıyla istatistiksel analizlerle (örneğin, frekans oranı veya kesikli histogram analizi) seçilir. Ayrıca, birden fazla eşik değeri kullanılarak aynı veri setinden birden fazla ikili harita oluşturulabilir.

#### c) Çizgisel değişkenlerin mekânsal analizi

Fay mesafesi, bir hücrenin en yakın fay hattına olan uzaklığını ifade eder. Mineralizasyonun fay mesafesi ile değişimi analiz edilerek, faya yakınlığın mineralizasyon üzerindeki etkisi değerlendirilir. Bu amaçla önce her hücrenin en yakın fay hattına olan mesafesi hesaplanarak bir fay mesafesi haritası oluşturulur (Şekil 2 a). Bu haritalar, fayların mineralizasyon üzerindeki etkisinin uzaklığa bağlı değişimini analiz etmek için kullanılabilir.

Her mesafe kategorisi için mineralizasyon ile ilişkilendirme yapılır. Faylara yakın alanlarla

(düşük mesafe): mineralizasyon arasında daha güçlü ilişki beklenir. Fayın geçtiği hücreler doğrudan 1 (ilişkili) ile kodlanır. Fayların etkisini daha iyi temsil etmek için çevrelerinde bir tampon alanı (buffer) oluşturulabilir. Bunun için, fay hattının etkisini temsil etmek için belirli bir tampon mesafesi seçilir (örneğin, 100 metre, 500 metre, vb.). Tampon mesafesi, fayın jeolojik etkisini doğru bir şekilde temsil edecek şekilde jeolojik gözlemler veya literatür verileri temel alınarak belirlenir. Farklı tampon mesafeleri kullanılarak, aynı veri setinden farklı ikili haritalar üretilebilir. Fayın çevresindeki tampon alanı içinde kalan hücreler 1 ile kodlanır. Faylardan uzak (tampon mesafesinin dışında kalan) hücreler ilişkisiz kabul edilerek 0 ile kodlanır (Şekil 2b). Çizgisel özelliklerin tampon mesafesine göre bu şekilde yeniden sınıflandırılması, fayın mineralizasyon üzerindeki etkisini görselleştirmek için kullanılır.


Bu yöntemle, raster harita fay etkisinin “var/yok” durumunu gösteren bir ikili haritaya dönüştürülür. Haritalarda veri bulunmayan hücreler (örneğin, jeolojik haritalarda çalışma alanı dışındaki bölgeler) “boş değer” (null value) olarak kodlanır ve analizlere dahil edilmez.

Çok sınıflı haritalar CBS yazılımlarıyla ikili haritalara otomatik olarak dönüştürülebilir.

Çizelge 2. Faya olan uzaklık ve gözlemlenen/beklenen oranı.

Table 2. Distance to fault and observed/expected ratio.

| Faya Olan Uzaklık | Piksel Sayısı | Yatak Sayısı | Gözlemlenen/Beklenen Oranı |
|-------------------|---------------|--------------|----------------------------|
| 0                 | 9             | 1            | 1,1                        |
| 1                 | 21            | 3            | 1,4                        |
| 2                 | 17            | 0            | 0,0                        |
| 3                 | 16            | 3            | 1,9                        |
| 4                 | 14            | 2            | 1,4                        |
| 5                 | 9             | 0            | 0,0                        |
| 6                 | 6             | 0            | 0,0                        |
| 7                 | 4             | 0            | 0,0                        |
| 8                 | 3             | 1            | 3,3                        |
| 9                 | 1             | 0            | 0,0                        |



Şekil 2. Çok sınıflı çizgisel özelliklerin ikili haritalara dönüştürme.

Figure 2. Conversion of multi-class linear features into binary maps.

### Fay yoğunluğu analizi

Fay yoğunluğu, bir alandaki fayların toplam uzunluğunun birim alana oranı ile hesaplanır ve genellikle mineralizasyon ile fayların ilişkisini değerlendirmede kullanılır.

Fayyoğunluğu, genelde “FayYoğunluğu=Fay Uzunluğu /Hücre Alanı” formülüyle ifade edilir. Her hücredeki toplam fay uzunluğu hesaplanarak fay yoğunluğu haritası oluşturulur. Fay yoğunluğu değerleri kategorilere (örneğin

düşük, orta, yüksek) ayrılır. Her fay yoğunluğu kategorisi için, mineralizasyon ile ilişkili (pozitif kanıt ağırlıkları) ve ilişkisiz (negatif kanıt ağırlıkları) hücre sayıları belirlenerek, Eşitlik 2 ile kanıt ağırlıkları hesaplanır:

$$W^+ = \ln \left( \frac{P(F|M)}{P(F|-M)} \right), \quad W^- = \ln \left( \frac{P(-F|M)}{P(-F|-M)} \right) \quad (2)$$

Burada  $P(F|M)$ , mineralizasyon olan alanlarda belirli bir fay yoğunluğu kategorisinin olma olasılığıdır;  $P(F|-M)$ , mineralizasyon

olmayan alanlarda aynı kategorinin olma olasılığıdır.

Sonuç: Fay yoğunluğu haritası ile mineralizasyon arasında güçlü bir ilişki olup olmadığı bu ağırlıklar kullanılarak belirlenir.

#### Fay yönü analizi

Fay yönü, çizgisel yapıların doğrultularını ifade eder ve belirli doğrultular mineralizasyon ile ilişkili olabilir. Bu ilişkiyi açığa çıkarmak için fay doğrultuları genellikle azimut ( $0^\circ$ - $360^\circ$ ) cinsinden ölçülür ve kategorilere ayrılır (örneğin  $0^\circ$ - $45^\circ$ ,  $45^\circ$ - $90^\circ$  vb.). Çizgisel veriler, hücresel bir grid sistemine dönüştürülerek her hücrede baskın fay doğrultusu belirlenir. Fay yoğunluğu analizindeki gibi, her doğrultu kategorisi için kanıt ağırlıkları hesaplanır ve mineralizasyon ile ilişkilendirilen doğrultular belirlenir. Sonuçta fay yönü ile mineralizasyonun hangi doğrultularda daha güçlü bir ilişki gösterdiği ortaya çıkar.

#### Kanıt Ağırlıkları Hesabı

Frekans oranı, kanıt ağırlıkları yöntemi için bir olasılıksal ilişki ölçüsüdür, ancak bu yöntem yalnızca frekans oranına dayanmaz. Kanıt ağırlıkları yöntemi, Bayes teoremi temelinde çalışır ve mekânsal veri setlerinin her bir kanıt sınıfının ağırlık değerlerini hesaplamak için pozitif ( $W^+$ ) ve negatif ( $W^-$ ) kanıt ağırlıklarını kullanır.

Frekans oranı, pozitif ve negatif ağırlıkların hesaplanmasında önemli bir rol oynar:

$$W^+ = \ln(FO) = \ln\left(\frac{N_m / \sum N_m}{N / \sum N}\right), \quad W^- = \ln(1 - \min(FO, 1)) = \ln\left(\frac{(N - N_m) / \sum (N - N_m)}{N / \sum N}\right) \quad (3)$$

Çizelge 1'deki verileri kullanarak bu formüllerle her kanıt sınıfı için hesaplanan kanıt ağırlıkları Çizelge 3'te verilmiştir.

$W^+$  ve  $W^-$ , belirli bir kanıt sınıfının maden yatağı varlığı ya da yokluğuyla ilişkisini ölçer. Oysa maden bulunabilirlik analizinde genellikle

birden fazla kanıt (değişken veya sınıf) bulunduğundan, bir hücrede aynı anda birden fazla değişkenin (örneğin hem kaya türü hem faya uzaklık hem jeokimyasal anomali) etkisi olabilir. Bir hücrenin maden yatağıyla pozitif veya negatif ilişkisini belirlemek için hücredeki kanıt sınıflarının mekânsal olarak birleşiminden kaynaklanan birleşik etkisini ölçmeye ihtiyaç vardır. Tüm kanıtların birleşik etkisi  $S(C)$  değeri olarak ifade edilir.  $S(C)$ , farklı sınıfların olumlu ve olumsuz etkilerinin farkına dayanır ve bir veri katmanı ile mineralizasyon arasındaki ilişkinin gücünün bir ölçüsünü sağlar:

$$S(C) = \sum W^+ - \sum W^- \quad (4)$$

$S(C) > 0$  ise hücrenin mineralizasyonla pozitif, eğer  $S(C) < 0$  ise hücrenin mineralizasyonla negatif bir ilişkisi olduğu anlamına gelir.

#### Güncellenmiş (Ardıl) Olasılık [ $C$ ve $S(C)$ ]:

Her hücre için güncellenmiş veya ardıl (posterior) olasılık şu şekilde hesaplanır:

$$P(C \mid \text{Kanıt}) = \frac{e^{S(C)}}{1 + e^{S(C)}} \quad (5)$$

Hesaplanan ardıl olasılık değerleri, her bir raster hücresi için mineralizasyon potansiyelini ifade eder (Çizelge 4).

#### Sonuçların Görselleştirilmesi

Modelleme sonuçları (ardıl olasılık değerleri) maden bulunabilirlik haritaları şeklinde sunulur. Bu harita, hedef maden yataklarının bulunma olasılığını eşik değerleri kullanılarak yüksek, orta veya düşük potansiyel sınıflarını renklerle görselleştirir. Genellikle yüksek bulunabilirlik alanları için sıcak renkler (kırmızı, turuncu), düşük bulunabilirlik alanları için soğuk renkler (mavi, yeşil) kullanılır. Raporlama yapılırken, kullanılan veri setleri, yöntem, ağırlıklar ve doğrulama sonuçları ayrıntılı bir şekilde sunulur.

Çizelge 3. Kanıt sınıfları için  $W^+$  ve  $W^-$  hesaplamaları.Table 3. Calculation of  $W^+$  and  $W^-$  for evidence classes.

| Kanıt Sınıfı | $W^+ = \ln \left( \frac{N_m / \sum N_m}{N / \sum N} \right)$        | $W^- = \ln \left( \frac{(N - N_m) / \sum (N - N_m)}{N / \sum N} \right)$ | Toplam Ağırlık<br>$S(C) = W^+ - W^-$ |
|--------------|---------------------------------------------------------------------|--------------------------------------------------------------------------|--------------------------------------|
| 1            | $\ln \left( \frac{6/13}{25/100} \right) = \ln 1,846 \approx 0,613$  | $\ln \left( \frac{19/87}{25/100} \right) = 0,8736 \approx -0,135$        | $0.613 - (-0.135) = 0.748$           |
| 2            | $\ln \left( \frac{5/13}{36/100} \right) = \ln 1,068 \approx 0,066$  | $\ln \left( \frac{31/87}{36/100} \right) = 0,990 \approx -0,010$         | $0.066 - (-0.010) = 0.076$           |
| 3            | $\ln \left( \frac{1/13}{6/100} \right) = \ln 1,282 \approx 0,248$   | $\ln \left( \frac{5/87}{6/100} \right) = 0,958 \approx -0,043$           | $0.248 - (-0.043) = 0.291$           |
| 4            | $\ln \left( \frac{1/13}{33/100} \right) = \ln 0,233 \approx -1,455$ | $\ln \left( \frac{32/87}{33/100} \right) = 1,115 \approx 0,109$          | $-1.455 - 0.109 = -1.564$            |

Çizelge 4. Güncellenmiş (ardıl) olasılık değerlendirmelerinin hesaplanmış sonuçları.

Table 4. Computed results for updated (posterior) probability assessments.

| Kanıt Sınıfı | $W^+$  | $W^-$  | $S(C)$ | $P(C  \text{Kanıt}) = \frac{e^{S(C)}}{1 + e^{S(C)}}$ |
|--------------|--------|--------|--------|------------------------------------------------------|
| 1            | 0.613  | -0.135 | 0.748  | 0.678                                                |
| 2            | 0.066  | -0.010 | 0.076  | 0.519                                                |
| 3            | 0.248  | -0.043 | 0.291  | 0.572                                                |
| 4            | -1.455 | 0.109  | -1.564 | 0.173                                                |

### Model Geçerlemesi

Üretilen harita, bilinen maden yatakları ve saha verileri ile karşılaştırılarak doğrulanır. Haritanın doğruluğu, kesinlik ve duyarlılık ölçütleriyle değerlendirilir:

- Kesinlik (Precision): Modelin pozitif olarak tahmin ettiği örneklerden kaçının gerçekten pozitif olduğunu gösterir.

$$\text{Kesinlik} = \frac{\text{Doğru Pozitif}}{\text{Doğru Pozitif} + \text{Yanlış Pozitif}} \quad (6)$$

- Duyarlılık (Recall): Modelin gerçekte pozitif olan örneklerin ne kadarını doğru tespit ettiğini gösterir.

$$\text{Duyarlılık} = \frac{\text{Doğru Pozitif}}{\text{Doğru Pozitif} + \text{Yanlış Negatif}} \quad (7)$$

Doğrulama tamamlandıktan sonra, bulunabilirlik haritası karar vericilere ve uzmanlara görsel olarak sunulur. Doğrulamayı tamamlamak için şu ölçütler dikkate alınabilir:

- Kesinlik ve Duyarlılık Dengesi: Eğer kesinlik çok yüksek ancak duyarlılık düşükse, model çok fazla yanlış negatif üretmiş olabilir. Bu, birçok maden potansiyeli taşıyan alanın göz ardı edildiğini gösterebilir. Eğer duyarlılık yüksek ancak kesinlik düşükse, model çok fazla yanlış pozitif üretmiş olabilir. Bu

da gereksiz detayların model tarafından maden potansiyeli olarak işaretlendiği anlamına gelir. İdeal durumda, kesinlik ve duyarlılık arasında kabul edilebilir bir denge sağlanmalıdır.

- 2) F1-Skorunun Değerlendirilmesi: F1 skoru, kesinlik ve duyarlılığın harmonik ortalaması olarak hesaplanır:

$$F1 = 2 \times \frac{\text{Kesinlik} \times \text{Duyarlılık}}{\text{Kesinlik} + \text{Duyarlılık}}$$

F1 skoru 0.7 veya üzeri olması genellikle iyi bir model performansı olarak kabul edilir.

- 3) ROC Eğrisi ve AUC Değeri: ROC (Receiver Operating Characteristic) eğrisi, modelin ayırt edici gücünü gösterir. AUC (Area Under Curve) değeri 0.8 veya üzeri olduğunda modelin iyi bir performansa sahip olduğu kabul edilir.
- 4) Maden Sahaları ile Uyum: Model tarafından yüksek potansiyelli olarak tahmin edilen alanların önemli bir kısmının bilinen maden yatakları ile çakışması gerekir. Bilinen yatakların dışında kalan tahmin edilen yeni alanların jeolojik anlamlılığı incelenmelidir.
- 5) Bağımsız Veri ile Doğrulama: Model eğitim verisinden bağımsız bir test veri seti ile değerlendirilmelidir. Eğer farklı veri kümeleriyle yapılan testlerde benzer doğruluk sonuçları elde ediliyorsa, modelin genelleme kabiliyeti yüksektir.

Bu kriterler sağlanmadığı sürece modelin güvenilir olduğu söylenemez ve revize edilmesi gerekebilir.

### Genişletilmiş Kanıt Ağırlıkları Yöntemi

Klasik kanıt ağırlıkları yöntemi, maden bulunabilirlik analizinde güçlü bir araçtır ancak bazı sınırlamaları bulunmaktadır. Şöyle ki,

yöntem, farklı kanıt haritalarındaki öngörücü değişkenlerin birbirinden bağımsız olduğunu varsayar. Gerçekte birçok jeolojik değişken (örneğin, fayların varlığı ve hidrotermal alterasyonlar) arasında bağımlılık vardır. Ayrıca raster veri çözünürlüğü sabittir ve tüm çalışma alanında aynı öneme sahip kabul edilir. Ancak, bazı bölgeler daha ayrıntılı analiz gerektirir. Yöntem veri belirsizliği, ölçüm hataları ve örnekleme yanlılığını dikkate almaz. Son olarak her bir kanıtı ikili durumla değerlendirir (var-yok), bu da çok sınıflı verilerde bilgi kaybına yol açabilir.

Bu sınırlamaların üstesinden gelmek için Porwal ve Hale (2000) tarafından genişletilmiş kanıt ağırlıkları yöntemi geliştirilmiştir. Bu yöntemde faktörler arasındaki koşullu bağımlılığı modellemek için yöntemler (örneğin, lojistik regresyon, çoklu regresyon) eklenir. Farklı bölgeler için farklı ağırlık setleri kullanılabilir, böylece jeolojik bağlam daha iyi temsil edilir. Verilerdeki belirsizlikleri ve hataları dikkate alan modeller (örneğin, Monte Carlo simülasyonu) uygulanır. Uydu görüntüleri, jeofizik veri setleri gibi ek veri setleriyle veya makine öğrenimi algoritmalarıyla tahmin gücü artırılır.

### ANALİTİK HİYERARŞİ SÜRECİ (AHP)

Analitik Hiyerarşi Süreci (AHP), çok ölçütlü karar verme (ÇÖKA) problemlerini çözmek için geliştirilmiş bir yöntemdir ve maden bulunabilirlik analizi gibi karmaşık mekânsal problemlerde yaygın olarak kullanılan bir araçtır. AHP, karar verme sürecini, problemi hiyerarşik bir yapıya ayırarak sadeleştirir ve ölçütlerin göreceli önemlerini belirlemek için sistematik bir karşılaştırma süreci sunar. Bu yöntem, özellikle bilgiye dayalı analizlerde uzman görüşlerini karar sürecine dahil etmek için güçlü bir çerçeve sağlar.

AHP yönteminde karar verme süreci, genellikle üç seviyeli bir hiyerarşik yapıda modellenir:

- Amaç: Örneğin, “Potansiyel maden sahalarının belirlenmesi”.
- Ölçütler: Analize etki eden faktörler (örneğin, litoloji, fay yoğunluğu, alterasyon zonları).
- Seçenekler: Değerlendirilecek sahalar ya da hücreler.

AHP ile maden potansiyeli (prospectivity) değerlendirmesi raster hücre temelli veya saha (örneğin ruhsat sahaları) temelli olmak üzere iki farklı ölçekte yapılabilir.

Raster hücre temelli değerlendirme yaklaşımında çalışma alanı, CBS kullanılarak eşit boyutlu hücrelere bölünür (örneğin, 100 m x 100 m hücreler). Her hücre, maden potansiyeli ölçütlerine göre bağımsız olarak analiz edilir ve nihai bir “potansiyel skoru” atanır. Sonuçta, tüm çalışma alanını kapsayan ve her hücreye bir skor atanmış bir maden potansiyel haritası elde edilir.

Saha temelli değerlendirme yaklaşımında analiz, raster hücreler yerine daha büyük alan birimleri (örneğin, ruhsat sahaları, alt bölgeler, poligonlar) üzerinden yapılır. Her alan, ölçütlere göre bir bütün olarak değerlendirilir ve birleştirilmiş bir potansiyel skoru alır. Ruhsat sahası gibi alanlar genellikle farklı boyut ve şekillerde olabileceğinden, analiz, alanların ortalama ya da ağırlıklı skorlarına dayanır.

AHP yöntemini kullanarak bir maden bulunabilirlik analizi gerçekleştirmek için şu adımlar izlenir:

### Arama Modelinin ve Ölçütlerin Seçimi

Hedef belirlenir (örneğin, en iyi seçeneği belirlemek). Karar verme sürecinde dikkate alınacak ölçütler ve alt ölçütler tanımlanır.

Örnek olarak, Volkanik Masif Sülfür(VMS) yatağı kavramsal modeli seçilebilir. Bu modele uygun ölçütler belirlenir. Örneğin, VMS yatağı bulunabilirlik analizi için şu ölçütler dikkate alınabilir:

1. MSM: Masif Sülfür Mineralizasyonu (zonları)
2. MFV: Mafik-Felsik Volkanik Ardalınma
3. VSK: Volcano-Sedimanter Kayalar
4. HAZ: Hidrotermal Alterasyon Zonları (Serisit, klorit, kuvars)
5. JKA: Jeokimyasal Anomaliler (Cu, Zn, Pb, Au, Ag)
6. ETY: Ekshalatif Tortul Yapılar
7. JFA: Jeofizik Anomaliler (IP veya manyetik anomalileri)

### Veri Toplama ve Düzenleme

Seçilen ölçütlere ve seçeneklere uygun veriler toplanır. Verilerin kalitesi ve doğruluğu analizden önce kontrol edilir. Veriler karar sürecinde kullanılacak formata uygun şekilde düzenlenir (örneğin, CBS tabanlı veri formatına dönüştürülür).

### Ölçütlerin İkili Karşılaştırması

İkili karşılaştırma yöntemiyle ölçütlerin birbirine göre önem derecesi uzmanlar tarafından değerlendirilir. Bu amaçla Saaty'nin 1-9 ölçeği (Saaty,1980) kullanılarak ikili karşılaştırma matrisi oluşturulur (Çizelge 5). Bu ölçekte puanların anlamı 1: Eşit önem, 3: Orta düzeyde önemli, 5: Çok önemli, 7: Çok daha önemli ve 9: Mutlak önemli şeklindedir.

Bir ölçütün diğerine göre önem derecesi, tersine çevrilerek ifade edilir. Örneğin, bir ölçüt diğerinden iki kat önemliyse (2), tersi (1/2) olarak yazılır.

Çizelge 5. İkili Karşılaştırma Matrisi

Table 5. Pairwise Comparison Matrix.

| Ölçütler                             | MSM | MFV | VSK | HAZ | JKA | ETY | JFA |
|--------------------------------------|-----|-----|-----|-----|-----|-----|-----|
| Masif Sülfür Mineralizasyonu (MSM)   | 1   | 2   | 3   | 1.5 | 1.5 | 2   | 4   |
| Mafik-Felsik Volkanik Ardalama (MFV) | 1/2 | 1   | 2   | 1   | 1   | 1.5 | 3   |
| Volkanosedimanter Kayalar (VSK)      | 1/3 | 1/2 | 1   | 1/2 | 1/2 | 1   | 4   |
| Hidrotermal Alterasyon Zonları (HAZ) | 2/3 | 1   | 2   | 1   | 1.5 | 1.5 | 3   |
| Jeokimyasal Anomaliler (JKA)         | 2/3 | 1   | 2   | 2/3 | 1   | 1.5 | 2   |
| Ekshalatif Tortul Yapılar (ETY)      | 1/2 | 2/3 | 1   | 2/3 | 2/3 | 1   | 2   |
| Jeofizik Anomaliler (JFA)            | 1/4 | 1/3 | 1/4 | 1/3 | 1/2 | 1/2 | 1   |

Çizelge 6. Normalize Matris.

Table 6. Normalized Matrix.

| Ölçütler   | MSM   | MFV   | VSK   | HAZ   | JKA   | ETY   | JFA   |
|------------|-------|-------|-------|-------|-------|-------|-------|
| <b>MSM</b> | 0.229 | 0.308 | 0.267 | 0.257 | 0.225 | 0.222 | 0.211 |
| <b>MFV</b> | 0.114 | 0.154 | 0.178 | 0.171 | 0.150 | 0.167 | 0.158 |
| <b>VSK</b> | 0.076 | 0.077 | 0.089 | 0.086 | 0.075 | 0.111 | 0.211 |
| <b>HAZ</b> | 0.153 | 0.154 | 0.178 | 0.171 | 0.225 | 0.167 | 0.158 |
| <b>JKA</b> | 0.153 | 0.154 | 0.178 | 0.114 | 0.150 | 0.167 | 0.105 |
| <b>ETY</b> | 0.114 | 0.103 | 0.089 | 0.114 | 0.100 | 0.111 | 0.105 |
| <b>JFA</b> | 0.057 | 0.051 | 0.022 | 0.057 | 0.075 | 0.056 | 0.053 |

### Matrisin Normalize Edilmesi

İkili karşılaştırma matrisi normalize edilir. Yani her sütunun toplamı bir olacak şekilde değerler ölçeklenir.

Normalizasyon işlemi için her sütunun toplamı bulunur. Çizelge 6'daki matrisin sütun toplamı sırasıyla 1.sütun=4,375, 2. sütun=6,5, 3. sütun= 11,25, 4. sütun= 5,833 , 5. sütun= 6,667, 6. sütun= 9 ve 7. sütun=19'dir.

Her matris elemanı, kendi sütun toplamına bölünerek normalize edilir. Örneğin normalize edilmiş ilk eleman  $1/4,375 \approx 0,229$  olarak hesaplanır. Bu şekilde bulunmuş normalize

edilmiş matris elemanları Çizelge 6'da görülmektedir.

### Ölçüt Ağırlıklarının Hesaplanması

Normalize edilen matrsten her ölçütün ağırlığı (önem derecesi) hesaplanır. Ağırlıklar, karar sürecinde ölçütlerin etkilerini yansıtır.

Her bir ölçüt için ağırlık katsayıları normalize edilmiş matriste her satırın ortalaması alınarak bulunur. VMS örneğinde matris boyutu 7 olduğundan her satır toplamı  $n=7$ 'ye bölünür (Çizelge 7). Örneğin MSM ölçütünün

ağırlığı 
$$= \frac{0,229+0,308+0,267+0,257+0,225+0,222+0,211}{7} = 0.25$$
'tir.

Çizelge 7. Değerlendirme ölçütlerinin ağırlıkları.

Table 7. *Weighting of evaluation criteria.*

| Ölçütler                        | Satır Toplamı | Ağırlık= Satır Toplamı: n |
|---------------------------------|---------------|---------------------------|
| Masif Sülfür Mineralizasyonu    | 1,719         | 0,25                      |
| Mafik-Felsik Volkanik Ardalanma | 0,992         | 0,14                      |
| Volkanosedimanter Kayalar       | 0,725         | 0,10                      |
| Hidrotermal Alterasyon Zonları  | 1,206         | 0,17                      |
| Jeokimyasal Anomaliler          | 1,121         | 0,16                      |
| Ekshalatif Tortul Yapılar       | 0,749         | 0,11                      |
| Jeofizik Anomaliler             | 0,371         | 0,05                      |

### Tutarlılık Oranı (CR) Hesaplama

İkili karşılaştırma matrisindeki değerlendirmelerin tutarlı olup olmadığı tutarlılık oranı (CR) hesaplanarak kontrol edilir. CR değeri %10'un altındaysa değerlendirme tutarlıdır, aksi takdirde matrisi yeniden düzenlemek gerekir.

Tutarlılık oranı (CR), tutarlılık indeksinin (CI) rastgele tutarlılık indeksine (RI) oranı olarak tanımlanır:

$$CR = \frac{CI}{RI} \quad (8)$$

Tutarlılık indeksi (consistency index),

$$CI = (\lambda_{max} - n) / (n - 1) \quad (9)$$

formülüyle hesaplanır. Bu formülde yer alan  $\lambda_{max}$ , ikili karşılaştırma matrisinin tutarlılığını değerlendirmek için kullanılan özel bir matematiksel değeri temsil eder. Tutarlı bir matris için  $\lambda_{max}$  her zaman matrisin boyutuna eşittir (örneğin,  $n = 7$  ise  $\lambda_{max} = 7$ ). Matrisin tutarsızlığının bir ölçüsü olarak  $\lambda_{max}$ ,  $n$ 'den büyük bir değer alır.  $\lambda_{max}$  değeri aşağıda açıklandığı şekilde hesaplanır:

a) Matris (Çizelge 5) ile ağırlık vektörü (Çizelge 7) çarpımı ( $A \times w$ ) hesaplanır:

$$(A \times w)_1 = 1 \times 0,246 + 2 \times 0,142 + 3 \times 0,104 + 1,5 \times 0,173 + 1,5 \times 0,161 + 2 \times 0,107 + 4 \times 0,054 = 1,79$$

$$(A \times w)_2 = 1/2 \times 0,246 + 1 \times 0,142 + 2 \times 0,104 + 1 \times 0,173 + 1 \times 0,161 + 1,5 \times 0,107 + 3 \times 0,054 = 1,02$$

$$(A \times w)_3 = 1/3 \times 0,246 + 1/2 \times 0,142 + 1 \times 0,104 + 1/2 \times 0,173 + 1/2 \times 0,161 + 1 \times 0,107 + 4 \times 0,054 = 0,79$$

$$(A \times w)_4 = 2/3 \times 0,246 + 1 \times 0,142 + 2 \times 0,104 + 1 \times 0,173 + 1,5 \times 0,161 + 1,5 \times 0,107 + 3 \times 0,054 = 1,28$$

$$(A \times w)_5 = 2/3 \times 0,246 + 1 \times 0,142 + 2 \times 0,104 + 2/3 \times 0,173 + 1 \times 0,161 + 1,5 \times 0,107 + 2 \times 0,054 = 1,22$$

$$(A \times w)_6 = 1/2 \times 0,246 + 2/3 \times 0,142 + 1 \times 0,104 + 2/3 \times 0,173 + 1 \times 0,161 + 1,5 \times 0,107 + 2 \times 0,054 = 0,76$$

$$(A \times w)_7 = 1/4 \times 0,246 + 1/3 \times 0,142 + 1/4 \times 0,104 + 1/3 \times 0,173 + 1/2 \times 0,161 + 1/2 \times 0,107 + 1 \times 0,054 = 0,39$$

Buna göre  $\frac{(A \times w)_i}{w_i}$  değerleri Çizelge 8'deki gibi hesaplanır:

Çizelge 8.  $\frac{(A \times w)_i}{w_i}$  değerlerinin hesaplanması.

Table 8. Calculation of  $\frac{(A \times w)_i}{w_i}$  values.

|                                                                |                                                                |                                                                |                                                                |
|----------------------------------------------------------------|----------------------------------------------------------------|----------------------------------------------------------------|----------------------------------------------------------------|
| $\frac{(A \times w)_1}{w_1} = \frac{1,79}{0,246} \approx 7,28$ | $\frac{(A \times w)_2}{w_2} = \frac{1,02}{0,142} \approx 7,18$ | $\frac{(A \times w)_3}{w_3} = \frac{0,79}{0,104} \approx 7,21$ | $\frac{(A \times w)_4}{w_4} = \frac{1,28}{0,173} \approx 7,23$ |
| $\frac{(A \times w)_5}{w_5} = \frac{1,22}{0,161} \approx 7,18$ | $\frac{(A \times w)_6}{w_6} = \frac{0,76}{0,107} \approx 7,11$ | $\frac{(A \times w)_7}{w_7} = \frac{0,39}{0,054} \approx 7,15$ |                                                                |

Bu değerlerin ortalaması alınarak  $\lambda_{\max}$  bulunur:

$$\lambda_{\max} = \frac{1}{n} \sum_{i=1}^n \frac{(A \times w)_i}{w_i} = \frac{1}{7} (7,28 + 7,18 + 7,21 + 7,23 + 7,18 + 7,11 + 7,15) \approx 7,19$$

Buna göre tutarlılık indeksi,

$$CI = \frac{(\lambda_{\max} - n)}{(n-1)} = \frac{(7,19-7)}{(7-1)} = \frac{0,19}{6} \approx 0,32 \text{ hesaplanır.}$$

Rastgele tutarlılık indeksi RI, n boyutundaki matris için önceden tanımlı bir değerdir. Örneğin, matris boyutu (ölçüt sayısı) n=3 için RI=0.58, n=4 için RI=0.90, n=7 için RI=1.32 gibi. Bu değerler formülde yerlerine konursa, tutarlılık oranı;  $CR = \frac{CI}{RI} = \frac{0,032}{1,32} = 0,024$  bulunur. Bu CR değeri 0,1'in çok altındadır ve matrisin oldukça tutarlı olduğunu gösterir.

### Seçeneklerin Değerlendirilmesi

Belirlenen ölçüt ağırlıkları ve seçeneklere uzmanlar tarafından verilen puanlar çarpılarak her seçeneğin toplam puanı hesaplanır. Bu toplam puan, her seçeneğin ölçütlere göre performansını yansıtır.

$$\text{Toplam Puan} = \Sigma(\text{Ölçüt Ağırlığı}) \times (\text{Sahanın Puanı}) \quad (10)$$

Örneğin A, B ve C sahalarına ya da hücrelerine Çizelge 9'daki gibi puanlar verildiyse, bu formül kullanılarak seçenekler için Çizelge 10'da verilen toplam puanlar bulunur.

### Sonuçların Geçerlemesi

AHP yöntemiyle elde edilen sonucun ne kadar güvenilir olduğu şu yöntemlerden biri veya birkaçı birlikte kullanılarak değerlendirilebilir:

- Gerçek verilerle karşılaştırma ile yapılır. Eğer seçilen en ümit vaat eden saha içinde bilinen bir maden yatağı ya da daha önce yapılmış sondaj veya jeokimyasal analiz gibi veri setleri mevcutsa, AHP ile elde edilen sıralama bu verilerle karşılaştırılabilir.
- Duyarlılık Analizi: AHP'de kriter ağırlıklarının küçük değişiklikler göstermesinin sıralamayı nasıl etkilediğine bakılır. Eğer en ümit vaat eden saha, ağırlıkların değiştirilmesine rağmen hep en üstte kalıyorsa, modelin güvenilir olduğu söylenebilir. Ancak küçük değişiklikler sıralamayı önemli ölçüde değiştiriyorsa, modelin kararlılığı sorgulanabilir.
- Aynı veri seti kullanılarak TOPSIS, VIKOR, ELECTRE veya PROMETHEE gibi diğer çok ölçütlü karar verme yöntemleri ile analiz edilebilir. Eğer AHP ile elde edilen en iyi saha, diğer yöntemlerle de en iyi saha olarak belirleniyorsa, modelin güvenilirliği artar.

Özkan

Çizelge 9. Uzmanlar tarafından ölçütlere göre seçeneklere (saha veya hücre) verilen puanlar.

Table 9. Scores assigned by experts to alternatives (areas or grid cells) based on criteria.

| Ölçütler | MSM | MFV | VSK | HAZ | JKA | ETY | JFA |
|----------|-----|-----|-----|-----|-----|-----|-----|
| A Sahası | 3   | 4   | 5   | 3   | 2   | 4   | 2   |
| B Sahası | 4   | 3   | 3   | 4   | 5   | 2   | 3   |
| C Sahası | 2   | 2   | 4   | 3   | 4   | 3   | 5   |

Not: MSM= Masif Sülfür Mineralizasyonu, MFV= Mafik-Felsik Volkanik Ardalanma, VSK= Volcano-Sedimanter Kayalar, HAZ= Hidrotermal Alterasyon Zonları, JKA= Jeokimyasal Anomaliler, ETY= Ekshalatif Tortul Yapılar, JFA= Jeofizik Anomaliler.

Çizelge 10. Seçenek sahaların ölçüt ağırlıklarıyla hesaplanmış toplam puanları.

Table 10. Total scores for candidate sites calculated using criterion weights.

| Ölçüt                           | Ölçüt Ağırlığı | A Sahası |                 | B Sahası |                 | C Sahası |                 |
|---------------------------------|----------------|----------|-----------------|----------|-----------------|----------|-----------------|
|                                 |                | Puanı    | Ağırlıklı Puanı | Puanı    | Ağırlıklı Puanı | Puanı    | Ağırlıklı Puanı |
| Masif Sülfür Mineralizasyonu    | 0,25           | 3        | 0,75            | 4        | 1               | 2        | 0,5             |
| Mafik-Felsik Volkanik Ardalanma | 0,16           | 4        | 0,64            | 3        | 0,48            | 2        | 0,32            |
| Volkan sedimanter Kayalar       | 0,11           | 5        | 0,55            | 3        | 0,33            | 4        | 0,44            |
| Hidrotermal Alterasyon Zonları  | 0,18           | 3        | 0,54            | 4        | 0,72            | 3        | 0,54            |
| Jeokimyasal Anomaliler          | 0,15           | 2        | 0,3             | 5        | 0,75            | 4        | 0,6             |
| Ekshalatif Tortul Yapılar       | 0,11           | 4        | 0,44            | 2        | 0,22            | 3        | 0,33            |
| Jeofizik Anomaliler             | 0,05           | 2        | 0,1             | 3        | 0,15            | 5        | 0,25            |
| <b>Toplam Ağırlıklı Puan</b>    |                |          | <b>3,32</b>     |          | <b>3,65</b>     |          | <b>2,98</b>     |

Toplam puanlara göre seçenekler sıralanır ve en uygun maden bulunabilirlik alanları belirlenir. Yukarıdaki örnekte en yüksek toplam puana sahip B sahası, en ümit vaat eden saha olarak seçilir.

## Sonuçların Görselleştirilmesi

Analiz sonunda ulaşılan sonuçlar çizelgeler, grafikler şeklinde veya sonuçları CBS yazılımlarıyla mekânsal olarak temsil eden maden bulunabilirlik haritaları şeklinde sunulur. Maden bulunabilirlik haritaları, karar vericilere en iyi seçeneği net bir şekilde gösterir.

## LOJİSTİK REGRESYON ANALİZİ

Lojistik regresyon analizi, genellikle kategorik bir bağımlı değişkenin birden fazla bağımsız değişkenle (örneğin,  $x_1, x_2, \dots, x_n$ ) olan ilişkisini incelemek için kullanılan istatistiksel bir modeldir. Aynı zamanda denetimli bir makine öğrenimi algoritması olarak da tanımlanabilir. Bu analiz, bağımsız değişkenlerin bir bağımlı değişkenin gerçekleşme olasılığı üzerindeki

etkilerini modellemek amacıyla gerçekleştirilir. Yöntemin maden bulunabilirlik analizine uygulamaları konusunda çok sayıda yayın vardır (Örneğin Carranza ve Hale, 2001; Carranza vd., 2008).

Lojistik regresyon modelinin matematiksel temeli, lojistik fonksiyonu (veya sigmoid fonksiyonu) denilen eşitliktir. Bağımlı değişken ile bağımsız değişkenler arasındaki ilişkileri ifade eden bu fonksiyonun bağımlı değişkeni P maden yatağının var olma olasılığı, bağımsız değişkenler bağımlı değişken üzerinde etkili olan jeolojik, jeokimyasal, jeofiziksel özelliklerdir.


Lojistik regresyon modeli şu formülle ifade edilir (Porwal vd., 2010):

$$P(y = 1) = \frac{1}{1 + e^{-(b_0 + b_1 x_1 + b_2 x_2 + \dots + b_n x_n)}} \quad (11)$$

Bu yöntemde modelin eğitilmesi maden yatağı varlığı ile bağımsız değişkenler (yerbilim verileri) arasındaki mekânsal ilişkiyi en iyi yansıtan ağırlıkların ( $b_1, b_2, \dots, b_n$ ) neler olduğunu bulmaktır.

Lojistik veya sigmoid fonksiyonu, S-eğrisi şeklinde bir grafiğe sahiptir ve X çok küçük olduğunda P sıfıra, çok büyük olduğunda P bire yaklaşır (Şekil 3). Başka bir söyleyişle y eksenini boyunca 0 ile 1 arasında asimptotik sınırlar vardır, yani, fonksiyon hiçbir zaman tam olarak 0 veya 1 değerine ulaşmaz, ancak bu değerlere çok yaklaşır. Bu nedenle olasılık hesaplamaları için çok uygundur.

Maden bulunabilirlik analizi için lojistik regresyon analizinin uygulanması, daha anlaşılır olması için aşağıda basit bir örnek üzerinden açıklanmıştır.



Şekil 3. Tek bağımsız değişkenli (X) sigmoid fonksiyonunun grafiği.

Figure 3. Graph of the sigmoid function with a single independent variable (X).

### Modelin Eğitilmesi

#### a) Veri Setinin Hazırlanması

Lojistik regresyon analizinde önce bağımlı değişken ve analizin amacına uygun bağımsız değişkenler belirlenir. Maden bulunabilirlik analizinde bağımlı değişken, “maden yatağı var” veya “maden yatağı yok” gibi iki sınıflı bir değişkendir. Bağımsız değişkenler ise jeolojik, jeofizik ve jeokimyasal özellikler gibi maden bulunabilirliğini etkileyen faktörlerdir. Örneğin bir VMS yatağı bulunabilirlik analizinde bağımsız değişkenler olarak şunlar seçilebilir: (1) Masif sülfür mineralizasyonu, (2) Cu anomalisi, (3) Zn anomalisi, (4) Fay yoğunluğu ve (5)  $\delta^{34}\text{S}$  izotop değeri.

Bu değişkenlerle ilgili veriler toplanır, ölçeklendirilir veya standartlaştırılır. Anormal değerler temizlenir ve veri dengesizliği SMOTE gibi yöntemlerle giderilir. Veri dengesizliği, örneğin “maden var” sınıfının (1) çok az sayıda (mesela 10), buna karşın “maden yok” sınıfının (0) çok sayıda (mesela 90) olduğu durumlarda, modelin çok az sayıdaki sınıfı ihmal etme riskini ifade eder. Örneğin, bu durumda (10 var, 90 yok

durumunda) model tüm hücreler için “maden yok” dese bile %90 doğruluk gösterebilir. SMOTE (Synthetic Minority Over-sampling Technique), lojistik regresyon, karar ağaçları ve derin öğrenme gibi yöntemlerde dengesiz verileri dengelemek için kullanılan bir sentetik veri üretme yöntemidir. SMOTE, azınlık sınıfına (örneğin, maden yatağı olan bölgeler gibi) ait yeni, yapay veri noktaları üretir. Yapay veri noktaları azınlık sınıfındaki her veri noktası için, en yakın  $k$  komşusunu kullanma (KNN),  $X_{yeni} = X_{orijinal} + \lambda \times (X_{komşu} - X_{orijinal})$  formülü kullanılarak ara değerler üretme ( $\lambda$ , 0 ile 1

arasında rastgele bir sayıdır) yoluyla üretilir. Örneğin, “maden var” sınıfında 10 gözlem varsa ve SMOTE ile her gözlem için 4 yeni sentetik örnek üretilirse, azınlık sınıfındaki gözlem sayısı 50’ye çıkar. Bu sayede sınıf dengesizliği azaltılır ve modelin aşırı uyumu (overfitting) engellenir.

Belirtilen veri hazırlama işlemleri tamamlandıktan sonra örnek projemizde Çizelge 11’deki gibi 5 hücreden ibaret (bu sayı kolay anlaşılabilirliği sağlamak için düşük tutulmuştur) varsayımsal bir eğitim veri seti oluşturulduğunu kabul edelim.

Çizelge 11: Varsayımsal veri seti

Table 11: Hypothetical dataset.

| Hücre | $x_1$ :<br>Masif Sülfür<br>Mineralizasyonu (%) | $x_2$ :<br>Cu<br>Anomalisi<br>(ppm) | $x_3$ :<br>Zn<br>Anomalisi<br>(ppm) | $x_4$ :<br>Fay<br>Yoğunluğu<br>(km/km <sup>2</sup> ) | $x_5$ :<br>$\delta^{34}\text{S}$ İzotop<br>Değeri<br>(‰) | $y$ :<br>VMS<br>Yatağı<br>(0/1) |
|-------|------------------------------------------------|-------------------------------------|-------------------------------------|------------------------------------------------------|----------------------------------------------------------|---------------------------------|
| A     | 75                                             | 500                                 | 300                                 | 2,5                                                  | 2,0                                                      | 1                               |
| B     | 45                                             | 200                                 | 150                                 | 1,2                                                  | 0,5                                                      | 0                               |
| C     | 60                                             | 350                                 | 250                                 | 1,8                                                  | 1,0                                                      | 1                               |
| D     | 30                                             | 100                                 | 100                                 | 0,8                                                  | 0,2                                                      | 0                               |
| E     | 85                                             | 700                                 | 400                                 | 3,0                                                  | 2,5                                                      | 1                               |

Bu veri setine göre belirleyeceğimiz lojistik regresyon modelinin parametreleri aşağıda açıklanan yol izlenerek belirlenir:

Çizelge 12. VMS yatağı bulunabilirlik analizi için bağımsız değişken matrisi, bağımlı değişken vektörü ve katsayı vektörü.

Table 12. Independent variable matrix, dependent variable vector, and coefficient vector for VMS deposit prospectivity analysis.

| Bağımsız Değişken Matrisi (X)                                                                                                                                                                              | Bağımlı Değişken Vektörü (y)                              | Katsayı vektörü (b)                                                        |
|------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|-----------------------------------------------------------|----------------------------------------------------------------------------|
| $X = \begin{bmatrix} 1 & 75 & 500 & 300 & 2,5 & 2,0 \\ 1 & 45 & 200 & 150 & 1,2 & 0,5 \\ 1 & 60 & 350 & 250 & 1,8 & 1,0 \\ 1 & 30 & 100 & 100 & 0,8 & 0,2 \\ 1 & 85 & 700 & 400 & 3,0 & 2,5 \end{bmatrix}$ | $y = \begin{bmatrix} 1 \\ 0 \\ 1 \\ 0 \\ 1 \end{bmatrix}$ | $b = \begin{bmatrix} b_0 \\ b_1 \\ b_2 \\ b_3 \\ b_4 \\ b_5 \end{bmatrix}$ |

Burada 1, sabit terimi ( $b_0$ ) temsil eden sütundur. Katsayı vektörü rastgele veya sıfıra yakın değerlerle başlatılır

#### b) Katsayı Vektörünün Başlatılması

Bağımsız değişkenler ( $x$ ) ve bağımlı değişken ayrılarak bir katsayı vektörü ( $b$ ) başlatılır. Bağımsız değişkenler ( $x$ ), modelin girdi değişkenleridir ve genellikle bir matris olarak temsil edilir. Bağımlı değişken ( $y$ ), modelin tahmin etmeye çalıştığı sonuç değişkenidir. Katsayı vektörü ( $b$ ), modelin öğrenmeye çalıştığı parametreleri ifade eder. Başlangıçta genellikle sıfır veya rastgele değerler atanır. Bu, yinelemeli algoritmaların (örneğin gradyan inişi) optimize edilecek bir hedef fonksiyonu üzerinden parametreleri iyileştirmesine olanak tanır.

Örnek olarak ele alınan VMS projesi için bağımsız değişken matrisi, bağımlı değişken vektörü ve katsayı vektörü, Çizelge 11'deki verilere göre Çizelge 12'de gösterilmiştir.

#### c) Log-Olasılık Fonksiyonunun Optimizasyonu:

Lojistik regresyon katsayıları, veriye en iyi uyacak şekilde optimize edilir. Bunun için Maksimum Olabilirlik Tahmini (Maximum Likelihood Estimation "MLE") veya gradyan inişi gibi yöntemler kullanılır.

Maksimum olabilirlik fonksiyonu şu şekilde ifade edilir:

$$L(b) = \prod_{i=1}^m [P(y_i|x_i)]^{y_i} \times [1 - P(y_i|x_i)]^{1-y_i} \quad (12)$$

Negatif logaritması alınarak log-olabilirlik fonksiyonu elde edilir:

$$l(b) = -\sum_{i=1}^m [y_i \log(P(y_i|x_i)) + (1 - y_i) \log(1 - P(y_i|x_i))] \quad (13)$$

Optimizasyon sonucunda regresyon katsayıları bulunur. Örneğin, VMS veri seti için Python ile yapılan analiz sonucunda hesaplanan katsayılar şu şekildedir:

- $b_1$  (sabit terim): -29.0623
- $b_2$  (Masif Sulfür): 0.0071
- $b_3$  (Cu Anomalisi): 0.0703
- $b_4$  (Zn Anomalisi): 0.0469
- $b_5$  (Fay Yoğunluğu): 0.0003
- $b_6$  ( $\delta^{34}\text{S}$  İzotopu): 0.0002

Bu katsayılar formüldeki yerlerine konduğunda lojistik regresyon denklemi bulunur:

$$l(b) = -\sum_{i=1}^m [y_i \log(P(y_i|x_i)) + (1 - y_i) \log(1 - P(y_i|x_i))]$$

#### Modelin Test Edilmesi

Model, eğitim verisinden bağımsız (modelin geliştirilmesinde kullanılmamış) bir test veri seti ile değerlendirilir. Performansı, doğruluk, duyarlılık, özgüllük, F1 skoru ve ROC eğrisi gibi metriklerle ölçülür. Eğer farklı veri kümeleriyle yapılan testlerde benzer doğruluk sonuçları elde ediliyorsa, modelin genelleme kabiliyeti yüksek kabul edilir. Ayrıca, eğer ümit vaat eden bir saha olarak öngörülen bölgede bilinen bir maden yatağı, daha önce yapılmış sondajlar veya jeokimyasal analizlerden oluşan bir veri seti mevcutsa, lojistik regresyon analizinin ürettiği sıralama bu verilerle karşılaştırılarak test edilebilir.

Doğruluk, duyarlılık, özgüllük, F1 skoru ve ROC eğrisi gibi metrikler 3.7 bölümünde açıklandığından burada tekrar edilmemiştir. Örnekte gerçek veri setleri kullanılmadığı için modelle ilgili herhangi bir test sonucu verilmemiştir.

#### Tahmin Yapılması

Model, yeni veri noktalarının bağımlı değişkenini tahmin etmek için kullanılır. Örneğin VMS projesinde bağımsız değişken değerleri Çizelge 13'te verilen E ve F sahalarının var olma olasılığı Çizelge 14'te görüldüğü gibi hesaplanabilir:

Çizelge 13. Bağımsız değişkenlerin iki sahada (veya hücrede) gözlenen değerleri.

Table 13. Observed values for independent variables in two areas (or grid cells).

| Saha | $x_1$ | $x_2$ | $x_3$ | $x_4$ | $x_5$ |
|------|-------|-------|-------|-------|-------|
| E    | 75    | 250   | 400   | 2,0   | 2,5   |
| F    | 25    | 200   | 150   | 1,0   | 0, 05 |

Çizelge 14. İki saha (veya hücre) için maden yatağı var olma olasılıklarının hesaplanması.

Table 14. Probability calculations for mineral prospectivity in two areas (or grid cells).

| Saha | Logit fonksiyonu                                                                     | Olasılık                |
|------|--------------------------------------------------------------------------------------|-------------------------|
| E    | $-29.0623+0.0071(75)+0.0703(250)+0.0469(400)+0.0003(2.0)+0.0002(2.5)\approx 60.524$  | $P(y=1)\approx 0.9996$  |
| F    | $-29.0623+0.0071(25)+0.0703(200)+0.0469(150)+0.0003(1.0)+0.0002(0.05)\approx -8.103$ | $P(y=1)\approx 0.00041$ |

Bu sonuçlara göre, E sahasında VMS yatağı bulunma olasılığı çok yüksek, F sahasında ise çok düşüktür.

Genellikle, bir eşik değeri (örneğin,  $P(y=1)>0.5$ ) kullanılarak sınıflandırma yapılır.

## MAKİNE ÖĞRENMESİ VE YAPAY ZEKA YÖNTEMLERİ

Makine öğrenimi, bilgisayar sistemlerinin deneyim ve verilerden öğrenerek belirli görevleri otomatik gerçekleştirmesini sağlayan bir algoritmalar grubudur. Bu algoritmalar, maden yataklarının mekânsal ilişkilerini etkili bir şekilde ortaya çıkarma ve maden yatakları ile ilişkili karmaşık, doğrusal olmayan ilişkileri modelleme yetenekleri nedeniyle büyük ilgi görmektedir. Özellikle derin öğrenme ve rastgele ormanlar gibi teknikler, bu alanda dikkat çekmektedir.

Makine öğrenimi, 1990’larda Bonham-Carter ve Agterberg gibi araştırmacılar tarafından maden arama ve jeolojik modelleme alanında kullanılmaya başlanmıştır (Bonham-Carter vd., 1989). Ancak o dönemdeki işlem gücü yetersizliği, makine öğrenimi uygulamalarını

sınırlamıştır. 2000’lerden itibaren bilgisayar teknolojilerindeki gelişmelerle birlikte, maden bulunabilirlik analizlerinde önemli bir araç haline gelmiştir (Porwal ve Carranza, 2015; Carranza ve Laborte, 2015; Zuo, 2020; Zuo ve Carranza, 2011; Zuo vd., 2019). Makine öğrenimi teknikleriyle yapılmış maden bulunabilirlik analizlerine örnek olarak şu çalışmalar gösterilebilir:

- Yapay sinir ağları ile yapılmış çalışmalar Singer ve Kouda, 1999; Harris ve Pan, 1999; Brown vd., 2000; Porwal vd., 2003; Zuo vd., 2019; Sun vd., 2020),
- Derin öğrenme tekniği ile yapılmış çalışmalar (Yang vd. 2022),
- Destek vektör makineleri ile yapılmış çalışmalar (Carranza ve Hale, 2001; Zuo ve Carranza, 2011; Abedi vd., 2012),
- Karar ağaçları ve rastgele ormanlar (random forests) teknikleri ile yapılmış çalışmalar (Carranza ve Laborte, 2015).

Geleneksel veri odaklı yöntemlerden (örneğin, kanıt ağırlıkları veya lojistik regresyon) farklı olarak, makine öğrenimi, karmaşık ve doğrusal olmayan ilişkileri keşfetme kapasitesine

sahiptir ve çok büyük veri kümelerinden anlamlı sonuçlar çıkarabilir. Geleneksel yöntemler, genellikle parametrik modellere dayanırken, makine öğrenimi, verilerden model yapısını ve ilişkileri otomatik olarak öğrenme yeteneğiyle diğer yöntemlerden ayrılır.

## SONUÇ

CBS (Coğrafi Bilgi Sistemleri) tabanlı maden bulunabilirlik analizi son 30-35 yılda dünyada gittikçe gelişmekte ve buna paralel olarak uygulamaları yaygınlaşmaktadır. Günümüzde maden potansiyelini tahmin etmek için kullanılan CBS tabanlı birçok yöntem vardır. Bu yöntemler, matematiksel ve istatistiksel temellere dayanarak nesnel ve tekrarlanabilir sonuçlar sunar. Ayrıca, bu sonuçlar risk analizi süreçlerine doğrudan bütünleştirilebilir. Ancak, bir yöntem ne kadar gelişmiş veya karmaşık olursa olsun, yalnızca mineralizasyonu kontrol eden temel süreçleri ve jeolojik unsurları doğru şekilde temsil eden yüksek kaliteli verilerle anlamlı sonuçlar üretebilir.

Verilerin yeterliliği, doğruluğu ve temsil gücü, analizlerde kullanılan yöntemlerin sağlamlığı kadar önemlidir (Porwal vd., 2006). Eksik veya düşük kaliteli veri setleri yanıltıcı (yanlış pozitif veya yanlış negatif) sonuçlara yol açabilir:

Birçok ülke, yetersiz bilgi altyapısı nedeniyle madencilik potansiyelini tam anlamıyla değerlendirememekte ve sektör potansiyeli oranında büyümemektedir. Bu nedenle, jeolojik araştırma kurumlarının çağdaş arama modellerinin gereksinimlerine uygun yüksek kaliteli veri üretimine öncelik vermesi önemli bir gerekliliktir.

CBS tabanlı maden bulunabilirlik analizlerinde kullanılan veri setlerinin şu iki temel özelliğe sahip olması gerekir (Porwal ve Kreuzer, 2010):

1. Tarafsızlık: Veri seti, çalışılan bölgeyi önyargısız ve adil bir şekilde temsil etmelidir.
2. Eşit kapsama: Veri, bölgeyi homojen bir şekilde kapsamalıdır.

Bunlara üçüncü madde olarak “verilerin yeterliliği ve kalitesi” şartı da eklenebilir. Bu şartlardan herhangi birinin sağlanmaması, yanlı (biased) bir veri setine ve dolayısıyla hatalı analiz sonuçlarına neden olur.

Bu açılardan bakıldığında Türkiye jeolojik veri tabanının oldukça iyi bir durumda olduğu söylenebilir. Maden Tetkik ve Arama (MTA) Genel Müdürlüğü, tüm ülkenin 5.547 paftadan oluşan 1/25.000 ölçekli jeolojik haritalarını tamamlamış ve sayısallaştırmıştır. Türkiye Jeoloji Veri Tabanı litolojik, stratigrafik ve yapısal veri katmanlarını (fay, kıvrım eksen ve tabaka doğrultu/eğim, krater, volkan konisi vb.) içerir. Hidrotermal alterasyon zonları gibi önemli bilgiler eksiktir. Ancak bu eksiklikler uzaktan algılamayla kolayca tamamlanabilir.

Türkiye’nin jeofizik veri tabanında hat aralığı 250–1000 metre arasında değişen havadan bölgesel manyetik (toplam alan) ve gravite Bouguer haritaları mevcuttur. Bu haritalar 1/100.000 ve 1/500.000 ölçekli olarak sunulmaktadır. Türkiye bölgesel jeoelektrik haritaları (Neojen havzaları üzerine odaklanmıştır) ve radyometrik veri tabanı (potasyum, uranyum ve toryum anomalilerinin yayılımını belirlemek için) henüz tamamlanmamıştır.

Türkiye bölgesel jeokimya veri tabanında da ciddi eksiklikler söz konusudur. En başta dere çökeli örneklemesine dayanan bölgesel jeokimya verileri büyük oranda Karadeniz Bölgesi ve Kuzeybatı Anadolu’da (Marmara Bölgesi, Biga Yarımadası ve Trakya) yoğunlaşmış olup, ülkenin tamamını kapsamamaktadır. Farklı element kapsamına (genellikle 4 veya 8 element; 2010 yılından itibaren 30 element), farklı örnekleme yoğunluklarına (1–4 örnek/km<sup>2</sup>) ve farklı ve

hatta bazıları günümüz standartlarında anlamsız (örneğin 1990 öncesi altın analizlerinin tespit sınırı 20g/t Au'dur) tespit sınırlarına sahiptir. Bu jeokimya verileri yeniden örnekleme yoluyla çağdaş ihtiyaçları karşılayabilecek şekilde yeterli element kapsamı (en az 30 mümkünse 52 element) ve düşük tespit sınırlarıyla (örneğin 1-5 ppb Au) üretilerek homojen bir yapıda jeokimya veri tabanı bir an önce oluşturulmalıdır.

Belirtilen jeoloji, jeofizik ve jeokimya verilerine ek olarak eski ve işletilmekte olan maden yataklarının konumları, mineralojik/ petrografik / izotopik tayin verileri, sondaj verileri gibi diğer verilerin de ayrı katmanlar halinde, meta verilerle (verilerin nasıl toplandığı, işlendiği ve analiz edildiği hakkında bilgiler örneğin, koordinat sistemi, numune protokolleri) birlikte Türkiye Jeoloji Veri Tabanına eklenmesi büyük bir fayda sağlayacaktır.

Çağdaş maden potansiyelini tahmin etme ihtiyaçlarını karşılayabilmek için bu bilgi altyapısının ölçeklerinin ve çözünürlüklerinin sürekli güncellenmesi, kapsama alanlarının genişletilmesi gerekmektedir.

## KAYNAKLAR

- Abedi, M., Norouzi, G-H. ve Bahroudi, A. (2012). Support vector machine for multi-classification of mineral prospectivity areas. *Computers & Geosciences*, 46, 272-283.
- Agterberg, F.P. (1971). A probability index for detecting favourable geological environments. *Canadian Institute of Mining and Metallurgy*, 10, 82-91.
- Agterberg, F. P. (1973). Probabilistic Models to Evaluate Regional Mineral Potential. In: *Proc. Symposium on Mathematical Methods in the Geosciences*, Příbram. 3-38.
- Agterberg, F.P. (1974). Automatic contouring of geological maps to detect target areas for mineral exploration. *Math. Geol.*, 6, 373-395.
- Bonham-Carter, G.F., Agterberg, F.P. ve Wright, D.F. (1989). Weights of evidence modelling: a new approach to mapping mineral potential. Agterberg, F.P., Bonham-Carter, G.F. (Eds.), *Statistical Applications in the Earth Sciences: Geological Survey Canada Paper 89-9*, pp. 171-183.
- Agterberg F.P. ve Cheng, Q.M. (2002). Conditional independence test for weights-of-evidence modeling. *Nat Resour Res* 11,249-255.
- An, P., Moon, W. M. ve Rencz, A. N. (1991). *Application of Dempster-Shafer theory of evidence to mineral potential mapping. Computers & Geosciences*, 17(7), 889-896.
- Bliss, J.D., ed. (1992). Developments in deposit modeling. U.S. Geological Survey Bulletin 2004, 168 s.
- Bonham-Carter, G. F. (1994). *Geographic Information Systems for Geoscientists: Modelling with GIS*. Pergamon Press, 398s.
- Bonham-Carter, G.F., Agterberg, F.P., ve Wright, D.F. (1989). Weights of evidence modelling: a new approach to mapping mineral potential, in *Statistical applications in the earth sciences: Geol. Survey Canada Paper 89-9*, p. 171-183.
- Brown, W., Gedeon, T., Groves, D ve Barnes, R. (2000). Artificial Neural Networks: A New Method for Mineral Prospectivity Mapping. *Australian Journal of Earth Sciences*, 47. 757-770.
- Carranza, E. J. M. (2008). Geochemical anomaly and mineral prospectivity mapping in GIS. (Handbook of exploration and environmental geochemistry, Vol. 11). Elsevier.
- Carranza, E.J.M. (2009a). Chapter 7: Knowledge-Driven Modeling of Mineral Prospectivity. Emmanuel John M.(ed.), *Geochemical Anomaly and Mineral Prospectivity Mapping in GIS*, Elsevier Science B.V., 11, 189-247.
- Carranza, E.J.M. (2009b).Chapter 8: Data-Driven Modeling of Mineral Prospectivity. Emmanuel John M.(ed.), *Geochemical Anomaly and Mineral Prospectivity Mapping in GIS*, Elsevier Science B.V., 11, 249-310.
- Carranza, E.J.M. (2021). Mineral Prospectivity Analysis. Daya Sagar, B., Cheng, Q., McKinley, J., Agterberg, F. (eds) *Encyclopedia of Mathematical Geosciences. Encyclopedia of Earth Sciences Series*. Springer, Cham. 1-6.
- Carranza, E.J.M., Hale, M. (2001). Geologically constrained fuzzy mapping of gold mineralization potential, Baguio district, Philippines. *Natural Resources Research*: 10, 125-136.

- Carranza, E.J.M. ve Laborte, A.G. (2015). Random Forest predictive modeling of mineral prospectivity with small number of prospects and data with missing values in Abra (Philippines). *Comp. & Geosciences*, 74, 60-70.
- Carranza, E.J.M., Van Ruitenbeek, F.J.A., Hecker, C., van der Meijde, M. ve van der Meer, F.D. (2008). Knowledge-guided data-driven evidential belief modeling of mineral prospectivity in Cabo de Gata, SE Spain. *Int. J. Appl. Earth Observ. Geoinform.* 10 (3), 374–387.
- Cheng, Q. ve Agterberg, F. P. (1999). Fuzzy Weights of Evidence Method and Its Application in Mineral Potential Mapping. *Natural Resources Research* 8, 27–35
- Cox, D.P., Barton, P.B. ve Singer, D.A. (ed.). (1986). Mineral Deposit Models: U.S. Geological Survey Bulletin, 1693, 379s.
- Drew, L. J. ve Menzie, W. D. (1993). Is there is metric for mineral deposit occurrence probabilities: *Nonrenewable Resources*, 2,92–105
- Duda, R.O., Hart, P.E., Nilsson, N.J. ve Sutherland, G.L. (1978). Semantic network representations in rulebased inference systems. Waterman, D.A., Hayes-Roth, F. (Eds.), *Pattern-Directed Inference Systems*. Academic Press, 203–221.
- Ferri, C., Flach, P.A., Hernandez-Orallo, J. (2003) Improving the AUC of probabilistic estimation trees. *Proceedings of the 14th European Conference on Machine Learning*, 121–132.
- Harris, D.P. (1965). An application of multivariate statistical analysis to mineral exploration. Unpublished Ph.D. Dissertation, Pennsylvania State University, 261s.
- Harris, D.P. (1969). Alaska's base and precious metals resources: a probabilistic regional appraisal. *Quarterly of the Colorado School of Mines* 64, 295–327.
- Harris, D.P. ve Pan, G.C. (1999). Mineral favorability mapping: a comparison of artificial neural networks, logistic regression and discriminate analysis. *Natural Resources Research* 8, 93–109.
- Harris, J., Grunsky, E., Behnia, P. ve Corrigan, D. (2015). Data- and Knowledge driven mineral prospectivity maps for Canada's North. *Ore Geology Reviews*, 71, 788- 803.
- Hronsky, J.M.A. ve Groves, D.I. (2008). Science of targeting: definition, strategies, targeting and performance measurement. *Australian Journal of Earth Sciences* 55, 3–12.
- Hronsky, J. M. A. ve Kreuzer, O. P. (2019). Applying spatial prospectivity mapping to exploration targeting: Fundamental practical issues and suggested solutions for the future. *Ore Geology Reviews*, 107, 647–653.
- Knox-Robinson, C.M. ve Wyborn, L.A.I. (1997). Towards a holistic exploration strategy: using geographic information systems as tool to enhance exploration. *Australian Journal of Earth Sciences* 44, 453–463.
- Kreuzer, O.P., Etheridge, M.A., Guj, P., McMahon, M.E. ve Holden, D.J. (2008). Linking mineral deposit models to quantitative risk analysis and decision-making in exploration. *Economic Geology* 103, 829–850.
- McCuaig, T.C., Beresford, S. ve Hronsky, J. (2010). Translating the mineral systems approach into an effective exploration targeting system. *Ore Geology Reviews* 38, 128–138.
- McCuaig, T. ve Hronsky, J. (2000). The current status and future of the interface between the exploration industry and economic geology research. *Reviews in Economic Geology*. 13. 553-559.
- McCuaig, T. C. ve Hronsky, J. M. A. 2005, The Mineral Systems Concept: Key to Exploration Targeting: *Applied Earth Science IMM Transactions section B* 18(2):153-175
- McCuaig, T.C. ve Hronsky J.M.A. (2014). The mineral system concept: The key to exploration targeting. *Society of Economic Geologists Special Publication* 18, p. 153-175.
- Mosier, D.L ve Page, N.J. (1988). Descriptive and grade-tonnage models of volcanogenic manganese deposits in ocean environments—A modification: U.S. Geological Survey Bulletin, 1811, 28 s.
- Mosier, D.L, Berger., V.I. ve Singer, D. A. (2009). Volcanogenic Massive Sulfide Deposits of the World— Database and Grade and Tonnage Models: USGS, Open-File Report 2009-1034.
- Özkan, Y. Z. (2004). Maden Arama Projelerinin Tasarımı ve Değerlendirilmesi. *JMO Yayınları*, No.82.
- Özkan, Y. Z. (2023). Maden arama projelerinin optimizasyonu. *Mayeb Basın Yayın İnsan Kaynakları Ltd. Şti.*

- Özkan, Y. Z. (2024). Maden Kaynak Belirleme Sondaj Programlarının Optimizasyonu. *Jeoloji Mühendisliği Dergisi*, 48, 203-228.
- Pan, G. C., ve Harris, D. P. (2000). Information synthesis for mineral exploration. New York: Oxford University Press Inc. p. 460.
- Pirajno, F. (2009). *Hydrothermal Processes and Mineral Systems*. Springer.
- Porwal, A., Carranza, E.J.M. ve Hale, M. (2003). Artificial neural networks for mineral potential mapping: a case study from Aravalli province, western India. *Natural Resources Research* 12, 155-177.
- Porwal, A., Carranza, E.J.M. ve Hale, M. (2004). A hybrid neuro-fuzzy model for mineral potential mapping. *Mathematical Geology* 36, 803-826.
- Porwal, A., Carranza, E. J. M.ve Hale, M. (2003). A hybrid neuro-fuzzy model for mineral potential mapping. *Mathematical Geology*, 35(4), 403-424.
- Porwal, A. ve Carranza, E.J.M. (2015). Introduction to the special issue: GIS-based mineral potential modelling and geological data analyses for mineral exploration. *Ore Geol. Rev.* 71, 477-483.
- Porwal, A., Carranza, E.J.M. ve Hale, M. (2004). A Hybrid Neuro-Fuzzy Model for Mineral Potential Mapping. *Mathematical Geology*, 36(7), 803-826.
- Porwal, A., Carranza, E.J.M. ve Hale, M. A. (2006). Hybrid Fuzzy Weights-of-Evidence Model for Mineral Potential Mapping. *Nat Resour Res* 15, 1-14).
- Porwal, A.ve Hale, M. (2000). Extended weights of evidence modeling for predictive mapping of base metal potential: A case study in Aravalli province, western India. *Natural Resources Research*, 9(1), 59-76.
- Porwal, A., González-Álvarez, I., Markwitz, V., McCuaig, T.C. ve Mamuse, A. (2010). Weights of evidence and logistic regression modeling of magmatic nickel sulfide prospectivity in the Yilgarn Craton, Western Australia. *Ore Geology Reviews* 38, 184-196.
- Porwal, A.K. ve Kreuzer, O. P. (2010). Introduction to the Special Issue: Mineral prospectivity analysis and quantitative resource estimation: *Ore Geology Reviews*, 38, 121-127.
- Saaty, T. (1980). *The Analytic Hierarchy Process*. McGraw-Hill International Book Company.
- Sinclair, A.J. ve Woodsworth, G.L. (1970). Multiple regression as a method of estimating exploration potential in an area near Terrace, B.C. *Economic Geology* 65, 998-1003.
- Singer, D.A. (1972). Multivariate statistical analysis of the unit regional value of mineral resources. Unpublished Ph.D. Dissertation, Pennsylvania State University, 211 s.
- Singer, D.A., Berger, V.I. ve Moring, B.C. (2009). Sediment-hosted zinc-lead deposits of the world-database and grade and tonnage models. U.S. Geological Survey, Open-file Report 2009-1252
- Singer, D.A. ve Kouda, R. (1999). A comparison of the weights of evidence method and probabilistic neural networks. *Natural Resources Research* 8, 287-298.
- Sun, T., Li, H., Wu, K., Chen, F., Zhu, Z. ve Hu, Z. (2020). Data-Driven Predictive Modelling of Mineral Prospectivity Using Machine Learning and Deep Learning Methods- A Case Study from Southern Jiangxi Province, China. *Minerals* 2020, 10, 102.
- Wyborn, L. A. I., Heinrich, C. A. ve Jaques, A. L. (1994). Australian Proterozoic mineral systems: Essential ingredients and mappable criteria. P.C. Hallenstein (Ed.), *Australian Mining Looks North—the Challenges and Choices*, Australian Institute of Mining and Metallurgy Publication Series, 5 (1994), pp. 109-115.
- Yang, N., Zhang, Z., Yang, J. ve Hong, Z. (2022). Applications of data augmentation in mineral prospectivity prediction based on convolutional neural networks. *Comput. Geosci.*, 161
- Zhang, N. ve Zhou, K. (2015). Mineral prospectivity mapping with weights of evidence and fuzzy logic methods. *Journal of Intelligent & Fuzzy Systems*, 29, 6, 2639-2651.
- Zuo, R. (2020). Geodata Science-Based Mineral Prospectivity Mapping: A Review. *Nat Resour Res* 29, 3415- 3424.
- Zuo, R. ve Carranza, E.I J.M. (2011). Support vector machine: A tool for mapping mineral prospectivity. *Comput. Geosci.*, 37, 1967-1975.
- Zuo, R., Xiong, Y., Wang, J. ve Carranza, E.J.M. (2019). Deep learning and its application in geochemical mapping. *Earth-Sci. Rev.*, 192, 1-14