



Kahramanmaraş Sütçü İmam University

Journal of Engineering Sciences



Geliş Tarihi : 18.04.2023
Kabul Tarihi : 10.06.2023

Received Date : 18.04.2023
Accepted Date : 10.06.2023

MADENLERİN SINIFLANDIRILMASINA YÖNELİK HİBRİD BİR CNN MODELİN OLUŞTURULMASI

CREATING A HYBRID CNN MODEL FOR MINES CLASSIFICATION

Turab SELÇUK (ORCID: 0000-0002-8445-2105)

Kahramanmaraş Sütçü İmam Üniversitesi, Elektrik Elektronik Mühendisliği Bölümü, Kahramanmaraş, Türkiye

*Sorumlu Yazar / Corresponding Author: Turab SELÇUK, tselcuk@ksu.edu.tr

ÖZET

Madenlerin ülkelerin ekonomisindeki yeri oldukça büyüktür. Bu nedenle madencilikte cevher yataklarının tespiti ve tanımlanması önemli bir araştırma konusudur. Cevher sınıflandırılması işlemlerinde de bilgisayar tabanlı karar destek sistemleri kullanılmaktadır. Bu çalışmada yedi farklı cevherin sınıflandırılmasına yönelik dört aşamadan oluşan hibrid bir CNN model oluşturulmuştur. Bu aşamalar, özellik çıkarımı, özellik birleştirme, özellik seçimi ve sınıflandırmadır. Özellik çıkarımı için, sınıflandırma problemlerinde yüksek başarımlar gösteren ResNet50, MobileNetV2 ve DenseNet201 mimarileri kullanılmıştır. Çıkarılan özellikler birleştirilerek 1x3000 boyutlarında kapsamlı özellik vektörü elde edilmiştir. Sınıflandırma başarımını arttırmak için özellik vektörüne NCA, ReliefF ve mRMR algoritmaları uygulanarak ayırt ediciliği yüksek özellikler belirlenmiştir. Bu özellikler destek vektör makineleri ile sınıflandırılmıştır. Elde edilen sonuçlara göre mRMR için 91.34, NCA için 92.42 ve ReliefF için 93,14 doğruluk değeri göstermiştir. Sonuç olarak önerilen hibrid CNN modelinin cevher sınıflandırılmasında literatürdeki klasik CNN modellere göre daha yüksek başarımlar sağlamıştır. Önerilen hibrid CNN modelin jeoloji alanında cevher sınıflandırılmasına yönelik çalışmalarda araştırmacılara karar desteği sağlayacağı düşünülmektedir.

Anahtar Kelimeler: Maden Sınıflandırma, hibrid CNN modeli, özellik seçimi

ABSTRACT

The impact of mines on the economy of countries is quite large. For this reason, the detection and identification of ore deposits in mining is an important research topic. Computer-based decision support systems are also used in ore classification processes. In this study, a hybrid CNN model consisting of four stages was created for the classification of seven different ores. These stages are feature extraction, feature aggregation, feature selection and classification. ResNet50, MobileNetV2 and DenseNet201 architectures were used in feature extraction. By combining the extracted features, a feature vector of 1x3000 dimensions was obtained. In order to increase the classification performance, NCA, ReliefF and mRMR algorithms were applied to the feature vector and features with high distinctiveness were determined. These features are classified by support vector machines. According to the results obtained, it showed an accuracy value of 91.34 for mRMR, 92.42 for NCA and 93.14 for ReliefF. As a result, the proposed hybrid CNN model has higher performance in ore classification than the classical CNN models in the literature. It is thought that the proposed hybrid CNN model will provide decision support to researchers in studies on ore classification in the field of geology.

Keywords Mines Classification, hybrid CNN model, feature selection

GİRİŞ

Madenlerin ülkelerin ekonomisindeki yeri oldukça büyüktür. Bu nedenle madencilikte cevher yataklarının tespiti ve tanımlanması önemli bir araştırma konusudur. Cevherlerin sınıflandırılmasında renk, doku, koku özellikler kullanıldığı gelenekler yöntemler bulunmaktadır. Ancak bu geleneksel yöntemler, hem zaman alıcı hem de yüksek maliyet gerektiren süreçlerdir. Bu soruna çözüm olmak için birçok alanda olduğu gibi cevher sınıflandırılması işlemlerinde de bilgisayar tabanlı karar destek sistemleri kullanılmaktadır. Bu sistemler hızlı ve yüksek doğruluğa sahip sonuçlar elde edebilmektedir.

Cevherlerin bilgisayar tabanlı sistemlerle sınıflandırılması aslında bir görüntü sınıflandırma işlemidir. Sınıflandırma işlemlerinde de sıklıkla karar ağaçları, destek vektör makineleri kNN, Naive Bayes gibi algoritmalar kullanılmaktadır. Bu algoritmalar yüksek başarımlı göstermektedir. Ancak yüksek seviyede özelliklerin tanımlanmasını gerektirir. Evrişimli sinir ağları ihtiyaç olunan yüksek seviye özellik çıkarımını gerçekleştirmektedir. Sınıflandırılacak görüntüye ait çok sayıda özellik çıkarımı yapabilmektedir. Görüntüleme teknolojileri, işlemci donanımları ve makine öğrenmesi alanında yaşanan gelişmeler, cevherlerin sınıflandırılması noktasında da bu teknolojilerin kullanımına teşvik etti ve ilerlemeleri de beraberinde getirdi. Görünür ışık altındaki cevher özellikleri, bu sistemin temelini oluşturdu ve çalışmaların merkezinde görüntü işleme yer aldı. Son 10 yılda makine öğrenmesi çok çeşitli alanlarda tanıma ve sınıflandırma aracı olarak yaygın biçimde kullanılmıştır. Cevher sınıflandırılması alanında da akademisyenler çeşitli makine öğrenmesi algoritmalarını inceleyip değerlendirdiler. Bir karşılaştırmalı analizde, KNN, PNN, SVM, Naive Bayes algoritmaları arasında SVM'nin demir cevheri sınıflandırılmasında en yüksek doğrulukta performans ortaya koyduğunu buldular. (Patel vd., 2017). SVM algoritması, binary (ikili) sınıflandırma sağlayan ve denetimli öğrenmeye dayanan lineer bir sınıflandırıcıdır. Örneğin şekil, renk ve doku özellikleri üzerinden cevher sınıflandırılmasında yüksek performans gösterir. (Massinaei vd., 2012; Galdames vd., 2017; Patel vd., 2017; 2019; Min vd., Zhang vd., 2020b). Ek olarak, Support Vector Machine Regression'a (SVR) dayanan sequence forward floating selection (SFFS) gibi algoritmalar da demir cevher sınıfı tespitinde (Patel vd., 2018) ve kireç taşı sınıflandırmada iyi çalışır. (Chatterjee, 2013).

Ek olarak Karar ağacı (Perez vd., 2012), Naive Bayes (Khorram vd., 2017), KNN (Mollajan vd., 2016), ve Artificial Neural Network (ANN) (Sadeghiamirshahidi vd., 2013; Ebrahimi vd., 2016; Izadi vd., 2017) algoritmaları da cevher sınıflandırma da iyi performans gösterir. Bu araştırmalar, cevher sınıflandırmada makine öğrenmesi kullanımının avantajlarını ortaya koymaktadır. Fakat bu yöntemlerin endüstriyel kullanımı oldukça azdır. Çünkü yüksek görüntü kalitesi gereksinimi, endüstriyel doğruluk ve hız parametrelerini yeterince karşılayamamaktadır. Bu sebeple geleneksel makine öğrenmesi algoritmaları endüstriyel kullanımda yetersiz kaldığından yeni cevher görüntü sınıflandırma yöntemlerine ihtiyaç vardır. Derin öğrenme, makine öğrenmesi ile kıyaslandığında, derin öğrenme algoritmaları yüksek görüntü çözünürlüğü gereksinimlerini azaltır, özellik çıkarımı yaparak düşük ağırlıktaki özellikleri elimine eder ve böylece cevher sınıflandırma verimliliğini artırır. Ek olarak daha kısa eğitim süreleri ve daha hızlı sınıflandırmaya sunar. CNN algoritmalarının eğitim ve sınıflandırma başarı performansını belirleyen ana faktör model yapısıdır. Filtre konvolüsyonu ile güncellenen Inception ağına, konvolüsyon katmanları eklenerek oluşan AlexNet ve VGG Net ağlarından ve özellik aktarım yöntemiyle iyileştirilen ResNet ağına, cevher görüntü sınıflandırmasında derin öğrenmeye dayalı sınıflandırma modelinin performansı kademeli olarak iyileştirildi. Makine öğrenmesiyle karşılaştırıldığında, beş ile on katmanlı derin öğrenme modeli, sınıflandırma başarımlarını oldukça yükseltmiştir (Montes-Atenas vd., 2016); cevher görüntüsünün LeNet-5 modeli ile tanınması (Su vd., 2018); ham kömür görüntülerinin ve gang görüntülerinin sınıflandırılması (Gao vd., 2020) ve şeyl görüntülerinin U-Net modeline göre sınıflandırılması (Chen vd., 2020b); çelik yüzey yapısının YoloNet modeline göre sınıflandırılması (Li vd., 2018); demir cevherinin sekiz katmanlı CNN modeliyle sınıflandırılması (Iglesias vd., 2019) ve petrol kuyusu görüntülerinin on katmanlı küçük evrişimli sinir ağıyla sınıflandırılması (Imamverdiyev and Sukhostat, 2019). Ayrıca model derinliği de önemli bir husustur. AlexNet ve VGG Net tabanlı mimariler birçok araştırmacı tarafından tercih edilmekte ve cevher görüntüsü sınıflandırma işlevini verimli bir şekilde yerine getirmektedir. (Chaves vd., 2018; Fu and Aldrich, 2018; Wang vd., 2018; Pu vd., 2019). Ancak derin öğrenme sınıflandırma modelinin derinliğinin artması eğitim ve uygulamayı zorlaştırmaktadır. Bu sorunu çözmek için Han S. ve diğerleri, büyük ölçekli filtreler yerini alacak faktör dekompozisyonu ile sınıflandırma hızını artıran ve daha derin katmanlara izin vererek kayaları sınıflandırmak üzere bir Inception-v3 modeli oluşturdu. (Han vd., 2019).

Ek olarak ResNet, gradyan kaybolmasını ve gradyan patlamasını çözmek için Inception ağına dayalı kalıntı haritalama fikrini tanıttı. Örneğin, Baraboshkin ve ark. Rusya'daki farklı bölgelerin kaya görüntülerini sınıflandırmak için bir ResNet modeli oluşturmuştur (Baraboshkin vd., 2019). Ayrıca, birçok akademisyenin, farklı evrişimli sinir

ağlarını birleştirerek veya mükemmel sınıflandırma sonuçları elde eden büyük veri ve derin öğrenme gibi yeni teknolojileri birleştirerek cevher görüntü sınıflandırması için yeni modeller oluşturduğunu belirtmekte fayda var (Le vd., 2018; Xiong vd., 2018; Chen vd., 2020a; Si vd., 2020; Zhang vd., 2020c). Özetle, yapılan çalışmalar derin öğrenme modellerininin, yüksek çözünürlüklü cevher görüntülerine bağımlılığı azalttığını, az görüntüyle dahi makine öğrenmesine göre daha hızlı tanıma ve sınıflandırılma sağladığını kanıtlıyor.

Bu çalışmada cevherlerin sınıflandırılmasına yönelik, MobileNetV2, ResNet101 ve DenseNet201 olmak üzere üç farklı CNN mimariyi içinde bulunduran hibrid bir CNN model oluşturuldu. Bu model cevher görüntülerine ait özelliklerin çıkartılmasında kullanıldı. Her bir modelden elde edilen özellikler birleştirilerek kapsamlı bir özellik vektörü oluşturuldu. Elde edilen özelliklerden en ayırt edici olanları özellik seçim algoritmaları ile seçilerek SVM sınıflandırıcıya verildi. Elde edilen sonuçlar önerilen modelin başarılı bir şekilde cevher sınıflandırmasında hızlı ve güvenilir olduğunu göstermiştir.

VERİ KÜMESİ

Çalışmada Kaggle veriseti kullanıldı. (<https://www.kaggle.com/asiedubrempong/minerals-identification-dataset>) Bu verisetinde yedi farklı mineral sınıfı bulunmaktadır. Bu sınıflar biyotit, bornit, krizokol, malaşit, pirit ve kuartzdır. Toplamda 957 görüntü bulunmaktadır. Şekil 1’de her bir sınıfa ait örnek görüntüler gösterilmiştir. Veri setinin %70’i eğitim için %30’u ise test için ayrılmıştır. Tablo 1’de her bir sınıfa ait görüntü sayıları gösterilmiştir.



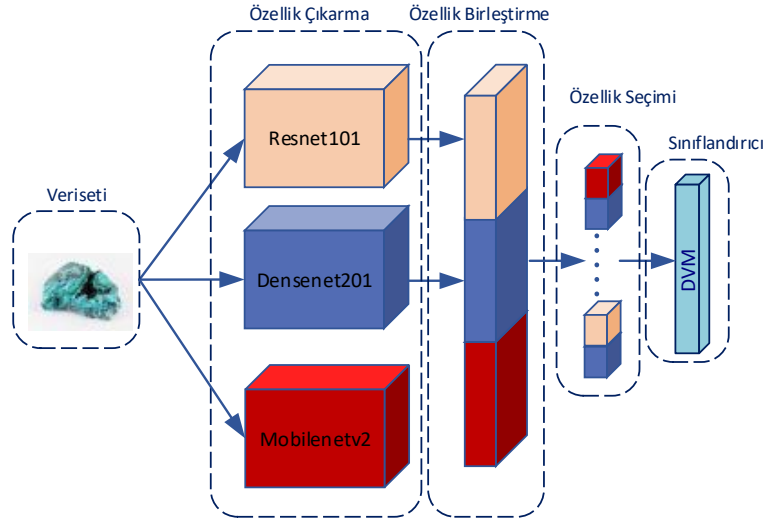
Şekil 1. Verisetinden Örnek Görüntüler

Tablo 1. Veri Setindeki Cevherlerin Görüntü Sayıları

Maden Tipi	Görüntü Sayısı
Biyotit	68
Bornit	170
Krizokol	164
Malaşit	235
Muskovit	77
Pirit	98
Kuartzdır	145
Total	957

YÖNTEMLER

Bu çalışmada minerallerin sınıflandırılmasına bilgisayar tabanlı bir sistem oluşturuldu. Bu sistem özellik çıkarımı sağlayan bir hibrid CNN modelinden, işlemci yükünü hafifleten özellik seçim algoritmalarından ve sınıflandırıcıdan oluşmaktadır. Çalışmada kullanılan yöntemler şekil 2’de özetlenmiştir.



Şekil 2. Çalışmadaki Yöntemleri Gösteren Akış Diyagramı

Özellik Çıkarımı

Özellik çıkarımında kullanılan hibrid model üç farklı CNN mimarisini içermektedir. Bu mimariler ResNet101, MobileNetV2 ve DenseNet201’dir. Herbir mimari ile 1x1000 boyutlarında özellik vektörleri oluşturulmuştur. Eşitlik 1,2 ve 3’te sırasıyla ResNet101, MobileNetV2 ve DenseNet201 ile özellik çıkarmanın matematiksel ifadesi verilmiştir.

$$F_R = ResNet101(I) \quad (1)$$

$$F_R = (f_{r1}, f_{r2}, \dots, \dots, \dots, f_{r1000})$$

$$F_M = MobileNetV2(I) \quad (2)$$

$$F_M = (f_{m1}, f_{m2}, \dots, \dots, \dots, f_{m1000})$$

$$F_D = DenseNet201(I) \quad (3)$$

$$F_D = (f_{d1}, f_{d2}, \dots, \dots, \dots, f_{d1000})$$

Burada F_R ResNet101 ile elde edilmiş özellik vektörünü, F_M , MobileNetV2 ile elde edilmiş özellik vektörünü ve F_D DenseNet201 ile elde edilmiş özellik vektörünü ifade etmektedir. I giriş görüntüsünü ifade etmektedir. F_R , F_M ve F_D 1x1000 boyutlarında olup $f_{r1}, f_{r2}, \dots, f_{r1000}$ sırasıyla 1000 adet özelliği ifade etmektedir. Önerilen hibrid modelde herbir CNN mimarisinin tam bağlı katmanından elde edilen 1000 özellik birleştirilmiştir. Birleştirilmiş özellik vektörü matematiksel olarak eşitlik 4’te ifade edilmiştir. F , 1x3000 boyutunda kapsamlı özellik vektörü ifade etmektedir.

$$F = (F_R, F_M, F_D) \quad (4)$$

$$F = (f_{r1}, f_{r2}, \dots, \dots, \dots, f_{r1000}, f_{m1}, f_{m2}, \dots, \dots, \dots, f_{m1000}, f_{d1}, f_{d2}, \dots, \dots, \dots, f_{d1000})$$

Özellik Seçimi

Özellik seçme, bir özellik vektörünün belirli kriterlere göre alt kümesinin oluşturulması işlemidir. İşlenecek verinin azaltılmasında ve gereksiz özelliklerin kaldırılmasında önemli rol oynar. Başarılı bir özellik seçimi, derin sinir ağlarının öğrenme performansını artırır, öğrenme süresini azaltır ve kolay bir şekilde öğrenme sonuçlarının elde edilmesini sağlar. Bu çalışmada yüksek başarıma sahip denetimli özellik seçim algoritmalarından (Max-Relevance and Min- Redundancy) MRMR ve ReliefF kullanılmıştır. Denetimli özellik seçim algoritmaları sınıflandırma problemlerinde sıklıkla kullanılır. Temel prensibi özellikler ile etiketler arasındaki ilişkiyi kullanır. Verilen bir veriseti için maksimum sınıflandırma başarımını elde eden özellik vektörünün alt kümesini bulmayı amaçlar.

$$D = (F, C) \quad (5)$$

$$F = (f_1, f_2, \dots, \dots, \dots, \dots, f_n)$$

$$F_s = (f_{s1}, f_{s2}, \dots, f_m)$$

Burada D bir veri kümesini, F özellik vektörünü, n , özellik vektörünün boyutunu, C ise veri setindeki sınıfları ifade etmektedir. F_s , F özellik vektörünün bir alt kümesi m ise seçilmiş özellik sayılarını ifade etmektedir.

En Küçük Artıklık En Büyük İlgililik (mRMR)

mRMR, en büyük ilgililik en küçük artıklık kriterine dayalı bir özellik seçme algoritmasıdır. Özellikler ile sınıf arasındaki ilgi ile özelliklerin kendi arasındaki fazlalık analiz edilmektedir. Bu analiz için öklit uzaklığı Pearson korelasyonu ve bilgi ölçümü yapılmaktadır. Sonuç olarak ham özellik vektörü dört gruba ayrılmaktadır. (a) tamamen ilişkisiz ve gürültülü özellikler (b) zayıf ilişkiye ve fazlalıklı özellikler (c) zayıf ilişki ve fazlalık olmayan özellikler (d) güçlü ilişkiye sahip özellikler. Bu durumda ilişki ve fazlalık analizi iki optimizasyon problemine dönüştürülür. Birincisi maksimum ilişki ve minimum fazlalığı sağlayan özellik alt kümesini elde etmektir. MRMR algoritmasında özellik vektörünün değerlendirilmesinde entropi ölçütü kullanılmaktadır. Eşitlik 6 ve eşitlik 7'de mRMR algoritmasına ait matematiksel ifade verilmiştir (Li BQ vd., 2012).

$$\text{Maximum Relevance}(MR) = \max \left[\frac{1}{|F|} \sum_{f_i \in F} D(f_i, C) \right] \quad (6)$$

$$\text{Minimum Redudancy}(mR) = \min \left[\frac{1}{|F|^2} \sum_{f_i \in F} \sum_{f_j \in F} D(f_i, f_j) \right] \quad (7)$$

ReliefF

Özellik seçiminde önem derecesini belirlemede kullanılan bir diğer algoritma ReliefF algoritmasıdır (K. Kira vd., 1992). Önem derecesi iki aşamalı olarak belirlenmektedir. İlk aşamada veri setinden bir örnek seçilir ve diğer örneklerle benzerliği karşılaştırılır. Benzer özelliklere sahip örneklerin özellik katsayıları arttırılır. İkinci aşamada seçilen örnek farklı sınıftaki örneklerin özellikleri karşılaştırılır ve bu özelliklerin etkisini azaltmak amacıyla katsayıları küçültülür. Bu iki aşamada verisetindeki her bir örnek için tekrarlanır. Bu sayede özelliklerin önem derecesi belirlenir. Bu önem derecesine göre özellikler sıralanır.

Komşuluk Bileşenleri Analizi (NCA)

NCA, öncelikle özellik vektöründeki her bir özelliğe rastgele katsayı ataması yapmaktadır. Sonrasındaki süreç bu katsayıların ağırlıklandırılmasıdır. Bu ağırlıklandırma işlemi, özelliklerin sınıflar üzerindeki etkisiyle doğru orantılı

olarak değişmektedir. Yüksek etkiye sahip özelliklerin yüksek değerli olarak ağırlıklandırılır düşük etkiye sahip özellikler ise düşük değerle ağırlıklandırılır. NCA'ya ait matematiksel ifade eşitlik 8'de verilmiştir.

$$\vec{w} = \arg_{w} \max \sum_{i=1}^n p_i - \lambda \sum_{r=1}^d w_r^2 \quad 8$$

Burada \vec{w} ağırlıklandırılmış vektörü ifade etmektedir. w_r ağırlık katsayılarını, p_i sınıflandırıcının doğruluk olasılığını ifade etmektedir. Burada λ ağırlık katsayılarının değiştirilmesi ile ilgili bir parametredir. Önemli özelliklere yüksek değer atanır önemsiz özelliklere düşük değerler atanır.

Sınıflandırma

Bu çalışmada yüksek başarımlı elde etmek ve basit formda olması nedeniyle SVM sınıflandırıcı kullanılmıştır. Oluşturulan sınıflandırıcıya ait parametreler tablo 2'de verilmiştir. Çalışmada çapraz doğrulama ile başarımlar test edilmiştir.

Tablo 2. Sınıflandırıcıya Ait Parametreler

Parametreler	Değerleri
SVM modeli	C-SVM
Çekirdek Fonksiyonu	RBF
Çekirdek Fonksiyonu parametresi, g	32
Düzeltilme Parametresi, c_p	1.414

UYGULAMA DETAYLARI

DeneySEL çalışmalar Matlab2021a ortamında yapılmıştır. Derin öğrenme araç kutusu kullanılarak CNN modeller oluşturuldu. Modellere ait eğitim parametreleri Tablo 3'te verilmiştir. SGD optimizyer kullanıldı, öğrenme oranı 1×10^{-4} , momentum 0,9 olarak seçilmiştir. Batch size 32 ve dropout 0.5 seçilmiştir. Döngü sayısı 450 dir. Donanım olarak Nvidia RTX 3070Ti GPU kullanılmıştır.

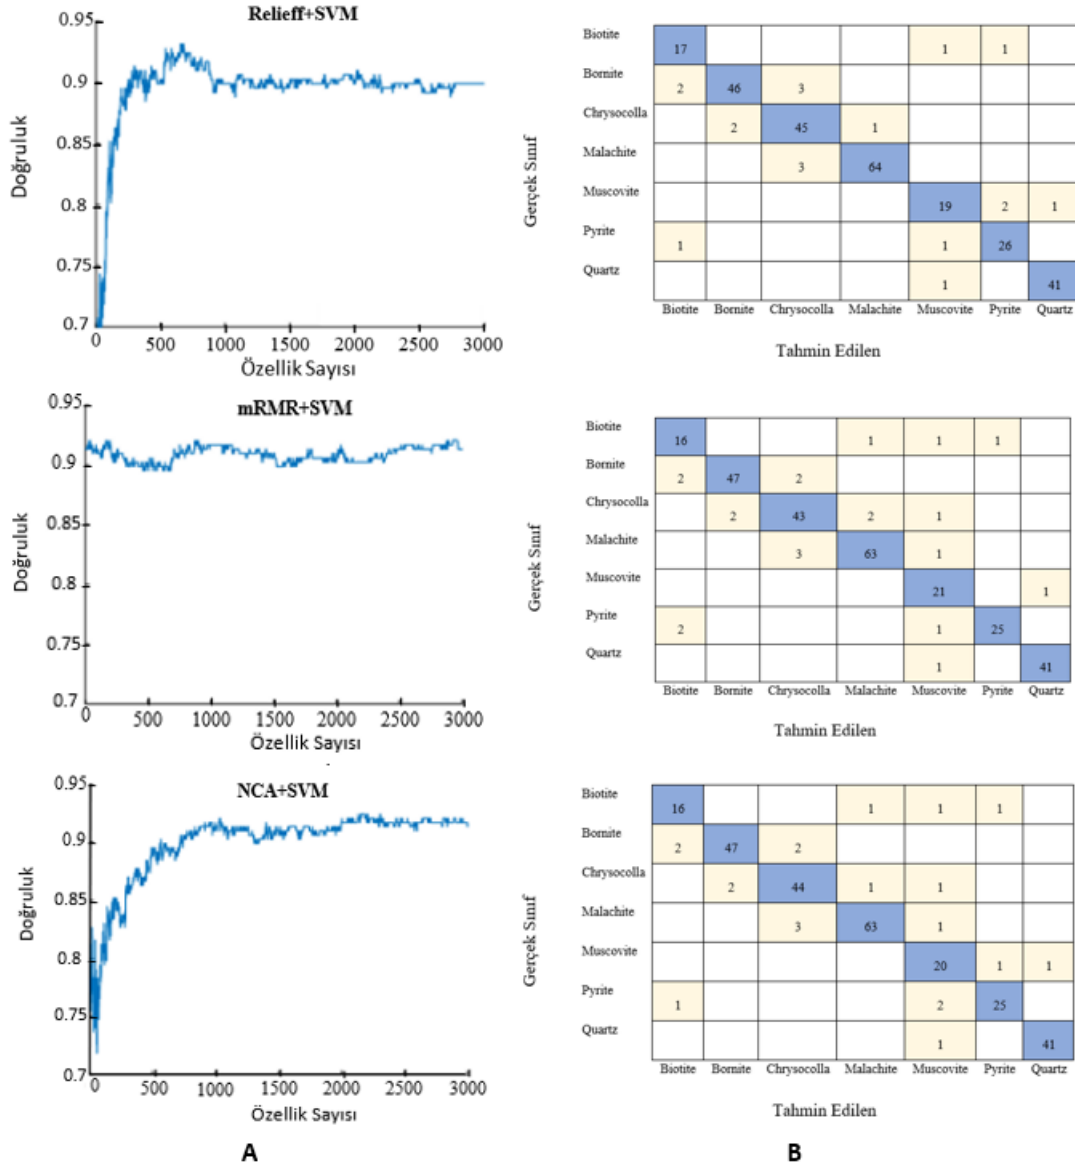
Tablo 3. Kullanılan Algoritmalara Ait Parametreler ve Donanım Özellikleri

	Parametre	Değeri
Eğitim	Döngü	450
	Batch boyutu	32
	Dropout	0,5
Optimizasyon	Optimizasyon adı	SGD
	Öğrenme oranı	1×10^{-4}
	Momentum	0,9
Donanım	GPU	Nvidia RTX 3070Ti
	Platform	Matlab2021a

BULGULAR VE TARTIŞMA

Çalışmada öncelikle olarak Resnet101, Densnet201 ve MobilenetV2 mimarileri ile ayrı ayrı veri setinin sınıflandırılması gerçekleştirildi. Resnet101 ile %85,2 Densnet201 ile %80,51 ve MobilenetV2 ile %77,26 elde edildi. ResNet101 diğer iki modele göre daha başarılı olduğu görüldü. İkinci olarak, önerdiğimiz hibrid CNN model ile sınıflandırma gerçekleştirildi. Bu modelde her mimarinin tam bağlı katmanından elde edilen 1×1000 boyutlarındaki özellik vektörleri birleştirilerek kapsamlı bir özellik vektörü oluşturulmuştur. Daha sonra sınıflandırma başarısında en etkili özellikler 3 özellik seçim algoritması ile belirlendi. Bunlar sırasıyla NCA, ReliefF ve mRMR idi. 1×3000 'lik özellik vektöründeki birinci özellikten başlanarak sırasıyla tüm özelliklerin eklendiği alt

vektörler oluşturulmuştur. Bu alt vektörlerin herbiri SVM ile sınıflandırılarak en yüksek başarıma sahip alt vektörü belirlendi. MRMR, NCA, Relief ile seçilmiş en iyi alt özellik vektörleri sırasıyla 29, 2132, 655 adet özelliği içermektedir. Bu alt özellik vektörleri ile tüm mineral sınıfları için en yüksek başarıma değerleri elde edilmiştir. Şekil 3a'da elde edilen doğruluk grafikleri Şekil 3b'de ise karmaşıklık matrisleri verilmiştir.



Şekil 3. . NCA, Relief ve MRMR İle Seçilmiş Özelliklerden Elde Edilen (A). Doğruluk Grafiği Ve (B). Karmaşıklık Matrisi

Şekil 3 incelendiğinde MRMR için 91.34 NCA için 92.42 ve Relief için 93.09 olarak elde edilmiştir. Özellikle sınıflandırma doğruluğu açısından değerlendirildiğinde Relief NCA'ya göre yaklaşık % 1 MRMR'ye göre yaklaşık % 2 daha başarılı sonuç vermiştir. NCA ile seçilmiş özellikler kullanılarak elde edilen doğruluk grafiği incelendiğinde 2132. özellikte % 92.42 olarak en yüksek doğruluk değeri elde edildiği görülmektedir. Karmaşıklık matrisleri incelendiğinde en yüksek sınıflandırma başarıma kuartz için elde edilmiştir. Toplamda 42 adet örnekten 41 tanesi doğru pozitif (TP) 1 tanesi yanlış negatif ve 1 tanesi yanlış pozitif olarak elde edilmiştir. Toplamda 19 örnek yanlış sınıflandırılmıştır.

SONUÇLAR

Cevher sınıflandırılması madencilik endüstrisinde büyük önem arz etmektedir. Çünkü madenlerin verimli bir şekilde işlenmesi ve bunun sonucunda yüksek kar elde etmek, doğru sınıflandırmayla doğrudan ilişkilidir. Özellikle cevherin kalitesinin belirlenmesi, cevherle ilişki diğer süreçlerin sağlıklı yürütülmesi, cevher işletimindeki zaman ve maliyet kaybını azaltır. Yapılan çalışmada cevher sınıflandırılmasına yönelik literatürdeki yüksek sınıflandırma başarıma

sahip üç farklı CNN mimarisini içeren bir hibrid CNN model oluşturulmuştur. Oluşturulan bu model sayesinde cevher görüntülerinin özellikleri çıkarılmıştır. Çalışmada, literatürde yaygın kullanılan CNN modelleri ile edilmiş özellik vektörlerinden daha kapsamlı bir özellik vektörü elde edilmiştir. Elde edilen özellikler arasında en belirleyici olanlar, özellik seçme algoritmaları ile seçilerek başarımın daha da artması sağlanmıştır. Özelliklerin sınıflandırılmasında destek vektör makineleri kullanılmıştır. Sonuç olarak önerilen modelin maden sınıflandırmaya yönelik çalışmalarda araştırmacılara yol gösterici olduğu düşünülmektedir.

KAYNAKLAR

Baraboshkin, E.E., Ismailova, L.S., Orlov, D.M., Zhukovskaya, E.A., Kalmykov, G.A., Khotylev, O. V., Baraboshkin, E.Y., Koroteev, D.A., 2019. Deep convolutions for in-depth automated rock typing. arXiv 135, 104330. <https://doi.org/10.1016/j.cageo.2019.104330>.

Chatterjee, S., 2013. Vision-based rock-type classification of limestone using multi-class support vector machine. *Appl. Intell.* 39, 14–27. <https://doi.org/10.1007/s10489-012-0391-7>.

Chaves, D., Fernández-Robles, L., Bernal, J., Alegre, E., Trujillo, M., 2018. Automatic characterisation of chars from the combustion of pulverised coals using machine vision. *Powder Technol.* 338, 110–118. <https://doi.org/10.1016/j.powtec.2018.06.035>.

Chen, J., Pisonero, J., Chen, S., Wang, X., Fan, Q., Duan, Y., 2020a. Convolutional neural network as a novel classification approach for laser-induced breakdown spectroscopy applications in lithological recognition. *Spectrochim. Acta – Part B At. Spectrosc.* 166, 105801 <https://doi.org/10.1016/j.sab.2020.105801>.

Ebrahimi, M., Abdolshah, M., Abdolshah, S., 2016. Developing a computer vision method based on AHP and feature ranking for ores type detection. *Appl. Soft Comput. J.* 49, 179–188. <https://doi.org/10.1016/j.asoc.2016.08.027>.

Fu, Y., Aldrich, C., 2018. Froth image analysis by use of transfer learning and convolutional neural networks. *Miner. Eng.* 115, 68–78. <https://doi.org/10.1016/j.mineng.2017.10.005>.

Galdames, A., Mendoza, A., Orueta, M., de Soto García, I.S., Sánchez, M., Virto, I., Vilas, J.L., 2017. Development of new remediation technologies for contaminated soils based on the application of zero-valent iron nanoparticles and bioremediation with compost. *Resource-Efficient Technologies* 3, 166e176.

Gao, R., Sun, Z., Li, W., Pei, L., Hu, Y., Xiao, L., 2020. Automatic coal and gangue segmentation using U-net based fully convolutional networks. *Energies* 13, 829. <https://doi.org/10.3390/en13040829>.

Han, S., Li, H., Li, M., Luo, X., 2019. Measuring rock surface strength based on spectrograms with deep convolutional networks. *Comput. Geosci.* 133, 104312 <https://doi.org/10.1016/j.cageo.2019.104312>.

Iglesias, J.C.´A., Santos, R.B.M., Paciornik, S., 2019. Deep learning discrimination of quartz and resin in optical microscopy images of minerals. *Miner. Eng.* 138, 79–85. <https://doi.org/10.1016/j.mineng.2019.04.032>.

Imamverdiyev, Y., Sukhostat, L., 2019. Lithological facies classification using deep convolutional neural network. *J. Pet. Sci. Eng.* 174, 216–228. <https://doi.org/10.1016/j.petrol.2018.11.023>.

Izadi, H., Sadri, J., Bayati, M., 2017. An intelligent system for mineral identification in thin sections based on a cascade approach. *Comput. Geosci.* 99, 37–49. <https://doi.org/10.1016/j.cageo.2016.10.010>.

K. Kira, L.A. Rendell, The feature selection problem: traditional methods and a new algorithm, in: *AAAI*, vol. 2, 1992a, pp. 129–134.

Khorrām, F., Morshedy, A.H., Memarian, H., Tokhmechi, B., Zadeh, H.S., 2017. Lithological classification and chemical component estimation based on the visual features of crushed rock samples. *Arab. J. Geosci.* 10, 1–9. <https://doi.org/10.1007/s12517-017-3116-8>.

Li BQ, Hu LL, Niu S, Cai YD, Chou KC (2012) Predict and analyze S-nitrosylation modification sites with the mRMR and IFS approaches. *J Proteomics* 75: 1654.1665

- Li, J., Su, Z., Geng, J., Yin, Y., 2018. Real-time Detection of Steel Strip Surface Defects Based on Improved YOLO Detection Network. *IFAC-PapersOnLine* 51, 76–81. <https://doi.org/10.1016/j.ifacol.2018.09.412>.
- Massinaei, M., Jahedsaravani, A., Taheri, E., Khalilpour, J., 2019. Machine vision based monitoring and analysis of a coal column flotation circuit. *Powder Technol.* 343, 330–341. <https://doi.org/10.1016/j.powtec.2018.11.056>.
- Mollajan, A., Ghiasi-Freez, J., Memarian, H., 2016. Improving pore type identification from thin section images using an integrated fuzzy fusion of multiple classifiers. *J. Nat. Gas Sci. Eng.* 31, 396–404. <https://doi.org/10.1016/j.jngse.2016.03.030>.
- Montes-Atenas, G., Seguel, F., Valencia, A., Bhatti, S.M., Khan, M.S., Soto, I., Becerra Yoma, N., 2016. Predicting bubble size and bubble rate data in water and in froth flotation-like slurry from computational fluid dynamics (CFD) by applying deep neural networks (DNN). *Int. Commun. Heat Mass Transf.* 76, 197–201. <https://doi.org/10.1016/j.icheatmasstransfer.2016.05.031>.
- Patel, A.K., Chatterjee, S., Gorai, A.K., 2017. Development of machine vision-based ore classification model using support vector machine (SVM) algorithm. *Arab. J. Geosci.* 10, 1–16. <https://doi.org/10.1007/s12517-017-2909-0>.
- Perez, C.A., Saravia, J., Navarro, C., Castillo, L., Schulz, D., Aravena, C., 2012. Lithological classification based on Gabor texture image analysis, in: 2012 International Symposium on Optomechatronic Technologies, ISOT 2012. IEEE, pp. 1–3. <https://doi.org/10.1109/ISOT.2012.6403273>.
- Sadeghiamirshahidi, M., Eslam Kish, T., Doulati Ardejani, F., 2013. Application of artificial neural networks to predict pyrite oxidation in a coal washing refuse pile. *Fuel* 104, 163–169. <https://doi.org/10.1016/j.fuel.2012.10.016>.
- Si, L., Xiong, X., Wang, Z., Tan, C., 2020. A Deep Convolutional Neural Network Model for Intelligent Discrimination between Coal and Rocks in Coal Mining Face. *Math. Probl. Eng.* 2020, 1–12. <https://doi.org/10.1155/2020/2616510>.
- Wang, X., Song, C., Yang, C., Xie, Y., 2018. Process working condition recognition based on the fusion of morphological and pixel set features of froth for froth flotation. *Miner. Eng.* 128, 17–26. <https://doi.org/10.1016/j.mineng.2018.08.017>.
- Xiong, Y., Zuo, R., Carranza, E.J.M., 2018. Mapping mineral prospectivity through big data analytics and a deep learning algorithm. *Ore Geol. Rev.* 102, 811–817. <https://doi.org/10.1016/j.oregeorev.2018.10.006>.
- Zhang, C., Yue, J., Qin, Q., 2020a. Deep quadruplet network for hyperspectral image classification with a small number of samples. *Remote Sens.* 12, 647. <https://doi.org/10.3390/rs12040647>.
- Zhang, Z., Liu, Ying, Hu, Q., Zhang, Zhiwei, Liu, Yang, 2020c. Competitive Voting-based Multi-class Prediction for Ore Selection, in: IEEE International Conference on Automation Science and Engineering. IEEE, pp. 514–519. <https://doi.org/10.1109/CASE48305.2020.9217017>.