

Bulanık Mantık Algoritmaları ile Kaya Sınıflandırması

Ebru EFEOĞLU^{1*} 

¹Kütahya Dumlupınar Üniversitesi Mühendislik Fakültesi Yazılım Mühendisliği Bölümü, KÜTAHYA

Geliş: 01.08.2023, Kabul: 20.12.2023, Yayınlanma: 31.12.2023

ÖZ

Kaya sınıflandırması tünel ve yeraltı çalışmalarının yanı sıra madencilik ve hidrokarbon araştırmalarında da önem teşkil eder. Kayaların türünün yanlış tespiti hem para hem de zaman kaybına yol açar. Bu çalışmada 4 farklı kaya sınıfının fiziksel ve mekanik özellikleri kullanılarak kaya sınıflandırması yapılmıştır. Sınıflandırma için Bulanık Sırasız Kural İndüksiyon Algoritması, Bulanık Kafes Akıl Yürütme, Çok Amaçlı Evrimsel Bulanık sınıflandırıcıları kullanıldı. Çok Amaçlı Evrimsel Bulanık MOE Bulanık sınıflandırıcısı, ENORA ve NSGA II algoritmalarına dayanmaktadır. Bu nedenle bu algoritmalar ayrı ayrı kullanılmıştır. Verilere sınıflandırma öncesi Sentetik Azınlık Aşırı Örnekleme Tekniği uygulanmış ve bu işlemten önceki ve işlem sonrasında sınıflandırma performansları karşılaştırılmıştır. Sonuç olarak Sentetik Azınlık Aşırı Örnekleme Tekniği ile sınıflandırma başarısının arttığı görülmüştür. Sınıflandırmada en başarılı algoritma FURIA algoritması olmuştur. Algoritmanın doğruluğu %93, hata değeri 0.16'dır.

Anahtar Kelimeler: Bulanık mantık algoritmaları; Kaya; Sınıflandırma; Yapay Zeka.

Rock Classification with Fuzzy Logic Algorithms

ABSTRACT

Rock classification is important in mining and hydrocarbon exploration as well as tunnel and underground work. Incorrect determination of the type of rocks leads to a waste of both money and time. In this study, physical and mechanical properties of 4 different rock classes have been used. For classification, Fuzzy Unordered Rule Induction Algorithm, Fuzzy Lattice Reasoning, Multi-objective Evolutionary Fuzzy classifiers have been used. The MOE Fuzzy classifier is based on the ENORA and NSGA II algorithms. Therefore, these algorithms have been used separately. The Synthetic Minority Oversampling Technique has been applied to the data before classification and the classification performances have been compared before and after this process. As a result, it has been observed that the classification success increased with the Synthetic Minority Oversampling Technique. The most successful algorithm in classification has the FURIA algorithm. The accuracy of the algorithm is 93% and the error value is 0.16.

Keywords: Fuzzy logic algorithms; Rock; Classification; Artificial Intelligence

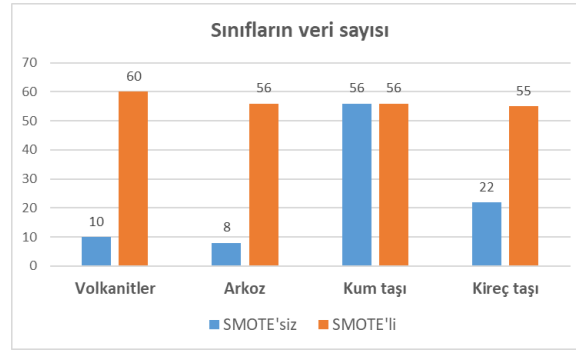
1. GİRİŞ

Yeraltı yapıları, tünel baraj gibi mühendislik projeleri için kayaların fiziksel ve mekanik özelliklerinin bilinmesi gerekir. Kayalar bu fiziksel ve mekanik özelliklerine göre sınıflandırılırlar. Bu projelerdeki tehlikelerin çođu kayaların türünün yanlış tespit edilmesinden kaynaklanır [1]. Bu nedenle kaya sınıflandırması mühendislik projelerinde önemli bir yere sahiptir. Öncelikle kaya sınıflandırılmasında kayaların fotoğraf görüntüleri kullanıldı. Bu görüntüler derin bir evrişimli sinir ađına girdi olarak verilip kaya sınıfı belirlendi [2]. Birleştirilmiş evrişimli sinir ađlarına dayalı petrografik ince kesit görüntülerde kaya sınıflandırması yapıldı [3]. Karbonat kaya mikro CT görüntüleri kullanılarak litolojik sınıflandırması yapıldı [4]. Gama ışını, öz direnç, nötron-yođunluk gözeneklilik farkı, ortalama nötron yođunluk ve jeolojik kısıtlama deđişkenleri derin evrişimli sinir ađına girdi parametreleri olarak kullanıldı ve kuyulardaki litolojik fasiyes sınıflandırması yapıldı [5]. Tünel çalışmalarını için derin öğrenme tabanlı kaya sınıflandırması yapıldı [6]. Kaya kütlesi sınıflandırmasında makine öğrenimi tekniklerinden faydalanıldı [7]. AdaBoost algoritması kullanılarak kaya kütlesi sınıfı tahmin edildi [8]. Dađ tünelinin kaya sınıflandırmasında sinir ađının uygulanabilirliđi araştırıldı [9]. Kaya kütlesi özelliklerini tahmin etmek için kaya sınıflandırmasını yeniden gözden geçirildi [10]. Entropi ađırlığına dayalı kaya kütlesi sınıflandırması yapıldı [11]. Zagros tüneli-B İran için çeşitli kaya kütlesi sınıflandırma/karakterizasyon sistemleri arasındaki korelasyonlar incelendi [12]. Kaya kütlesi sınıflandırmada çeşitli optimizasyon algoritmaları da kullanıldı. Parçacık Sürü Optimizasyonu En Küçük Kareler destek vektörüne dayalı tünel çevreleyen kaya kütlesi için bir sınıflandırma yöntemi önerildi [13]. Tünel mühendisliğinde kaya sıkıştırma sınıflandırması için gri kurt optimizasyonuna dayalı geliştirilmiş olasılıksal sinir ađı algoritması kullanıldı [14]. Konvolüsyonel Sinir Ađı kullanarak mineral kayaç sınıflandırması yapıldı [15]. Önemli öngörücü deđişkenleri tanıdıktan sonra kaya patlaması tahmini için akıllı sınıflandırma modelleri geliştirdi [16]. Fliş gibi tektonik olarak bozulmuş heterojen kaya kütlelerinin jeoteknik sınıflandırılması yapıldı [17]. Kaya sınıflandırması Maden ve hidrokarbon araştırmasında da önemli bir yere sahiptir. Maden ve hidrokarbon araştırması sondaj karotlarından çıkarılan jeolojik ve jeoteknik bilgilere dayanır. Geleneksel karot karakterizasyonu tamamen bir jeolođun uzmanlığına bađlıdır. Yeni teknolojiler, tahribatsız bir şekilde otomatik mineral analizi yapabilir. Bununla birlikte, otomatik kaya kütlesi karakterizasyonu önemli bir zorluk teşkil etmektedir. Bu bağlamda konvolüsyonel sinir ađları otomatik kaya kalitesi belirlemede kullanılmıştır [18]. Evrişimli sinir ađları kullanarak sondaj karot görüntülerinden otomatik litoloji sınıflandırması yapıldı [19], kaya geçirgenliğinin otomatik olarak sınıflandırılması için bir veri madenciliđi yaklaşımı önerilmiştir. Yapılan çalışmada altı sınıflandırma algoritması (k-NN, NB, C4.5, RF, SMO ve MLP) kullanıldı ve kayaların geçirgenliğini dört farklı sınıfa ayırdı [20]. Yapay zeka algoritmaları ile plütonik kayaların otomatik sınıflandırılması [21] ve ömür yolunu çevreleyen kayaçların

duyarlık tahmini yapıldı [22]. Ayrıca granitik sert kaya akiferleri bulunan alanlarda yeraltı suyu potansiyeli haritalaması için geleneksel sınıflandırma modelleri kullanıldı [23]. Döner sondaj işleminde titreşim sinyali kullanarak andezit, granit, kireçtaşı ve beton sınıflandırıldı [24]. Bu çalışmada volkanitler arkoz kumtaşı ve kireçtaşlarının mekanik ve fiziksel özellikleri kullanılarak bulanık mantık algoritmaları ile bu kayalar sınıflandırıldı. Bu çalışmada kullanılan veri seti ve sınıflandırma algoritmaları 2. Bölümde açıklanmış, algoritmaların performans değerlendirilmesi 3. Bölümde yapılmış ve sonuçları sunulmuştur. 4. Bölümde sonuçlar yorumlanarak çalışma sonlandırılmıştır.

2. MATERYAL VE METHOD

Çalışma için Kocaeli bölgesindeki beş bölgeden kaya örnekleri toplanmış ve laboratuvar testleri yapılmıştır. Laboratuvar testleri ile 10 volkanik ve 86 sedimanter kayaç olmak üzere toplam 96 kaya örneğinin P dalgası hızı, kuru birim ağırlığı, tek eksenli basınç dayanımı, Nokta Yük İndeksi, Brezilya Çekme Dayanımı, gözeneklilik ve Schmidt Geri Tepme Sayısı belirlenmiştir [1]. Bu değerler sınıflandırma için kullanılmıştır. Veri setinin dengesiz olması nedeniyle Sentetik Azınlık Aşırı Örnekleme Tekniği (Smote) kullanılmıştır. Bu teknik, veri setinde veri sayısı az olan sınıfları, sayıca çok olan sınıflarla eşitleyen bir tekniktir. Düşük sayıya sahip sınıftaki verileri sınıf içinde bulunan komşu verilere göre rastgele çoğaltarak yapar. Böylelikle sınıf dengesizliği problemi çözülmüş olur [25]. Daha sonra algoritmaların bu tekniği uygulanmadan ve bu teknik uygulandıktan sonraki sınıflandırma performansları karşılaştırılmıştır.



Şekil 1. Veri setindeki sınıfların örnek sayıları

2.1. Bulanık Sırasız Kural İndüksiyon Algoritması (FURIA)

Bulanık kural tabanlı bir algoritmadır. FURIA, geleneksel kurallar yerine bulanık kuralları ve kural listeleri yerine sırasız kural kümelerini öğrenir. [26]. Bu sayede veri setlerinden bulanık mantık kurallarını üretebilir. Ayrıca etkili bir kural esnetme yöntemi kullanır. Bu algoritma bir kural çıkarım algoritması olan RIPPER algoritmasını genişletilmiş halidir.

2.2. Bulanık Kafes Akıl Yürütme (FLR)

Bulanık kafes akıl yürütme algoritması olarak tasarlanmıştır. Oluşturulan bir matematiksel kafes içinde karar kuralı üretir [27]. Algoritmanın öğrenme hızı yüksektir. Aşamalı öğrenme söz konusudur. Öğrendiği kurallara bağlı kalır. Algoritma ayrıca eksik verilerle başa çıkma yeteneğine sahiptir.

2.3. Çok Amaçlı Evrimsel Bulanık (MOE Fuzzy)

ENORA veya NSGA-II Çok Amaçlı Evrim Algoritmasını kullanarak bulanık kural tabanlı bir sınıflandırıcı oluşturur. Bu sınıflandırıcının amacı, en yüksek doğrulukta sınıflandırma yapabilmek için kural sayısını ve hata oranını en aza indirip her bir bulanık küme setine dilbilimsel etiketleme yaparak sınıflandırma yapmaktır [28]. Bu sınıflandırıcı, ENORA ve NSGA II algoritmalarına dayanmaktadır. NSGA-II ile ENORA algoritmaları birbirlerinden popülasyon içindeki elemanların sıralamasının hesaplama şeklidir. ENORA algoritmasında, popülasyon içindeki bir elemanın sırası, o elemanın bulunduğu kümede baskın olmayacak bir düzeyde tutulur. NSGA-II algoritmasında ise baskın olmayacak seviyeye getirilir.

3. PERFORMANS DEĞERLENDİRMESİ

Volkanitler, arkoz, kum taşı ve kireç taşı 4 farklı bulanık mantık algoritması kullanılarak sınıflandırılmıştır. Sınıflandırma performanslarını karşılaştırmak için 10 kat çapraz doğrulama yöntemi kullanılmıştır. Eğitim ve 10 kat çapraz doğrulama yöntemi sonrasında elde edilen karışıklık matrisi Şekil 2'de verilmiştir.

		EĞİTİM				10-KAT ÇAPRAZ DOĞRULAMA					
		Tahmin edilen				Tahmin edilen					
		Volkanitler	Arkoz	Kumtaşı	Kireçtaşı		Volkanitler	Arkoz	Kumtaşı	Kireçtaşı	
FLR	Gerçek	Volkanitler	10	0	0	0	Volkanitler	9	0	0	1
		Arkoz	0	8	0	0	Arkoz	0	0	8	0
		Kumtaşı	0	0	56	0	Kumtaşı	1	0	55	0
		Kireçtaşı	0	0	17	5	Kireçtaşı	0	0	19	3
FURIA	Gerçek	Volkanitler	10	0	0	0	Volkanitler	9	0	0	1
		Arkoz	0	8	0	0	Arkoz	0	5	3	0
		Kumtaşı	0	0	53	3	Kumtaşı	1	0	52	3
		Kireçtaşı	0	1	3	18	Kireçtaşı	1	1	5	15
ENORA	Gerçek	Volkanitler	10	0	0	0	Volkanitler	9	0	0	1
		Arkoz	0	8	0	0	Arkoz	1	3	3	1
		Kumtaşı	1	2	45	8	Kumtaşı	1	0	47	8
		Kireçtaşı	2	0	6	14	Kireçtaşı	0	2	10	10
NSGA2	Gerçek	Volkanitler	0	0	0	10	Volkanitler	9	0	0	1
		Arkoz	0	8	0	0	Arkoz	0	4	4	0
		Kumtaşı	0	1	53	2	Kumtaşı	1	0	51	4
		Kireçtaşı	0	1	4	17	Kireçtaşı	2	0	10	10

Şekil 2. Eğitim ve çapraz doğrulama sonrası karmaşıklık matrisi

Şekil 2'ye göre bütün algoritmaların çapraz doğrulama yöntemi uygulandığında doğal olarak doğru tahmin ettikleri örnek sayısında bir azalma görülmektedir. Çapraz doğrulamada FURIA algoritması ile yapılan sınıflandırmada en yüksek doğru tahmin sayısına ulaşılmıştır. Algoritma bütün örneklerden sadece 15 tanesini yanlış sınıflandırmıştır. Algoritmaların eğitim ve çapraz doğrulama sonrası elde edilen metrik değerleri sırasıyla Çizelge 1 ve Çizelge 2'de verilmiştir. Çizelgelerde her sınıfın Doğru pozitif (DP) oranı, Yanlış pozitif (YP) oranı, Kesinlik, Duyarlılık, F-Skoru, MCC, AUC ve Kappa değerleri bulunmaktadır. Bu metrik değerlerinin olması çok iyi bir sınıflandırmanın gerçekleştiğinden söz edilebilir. Tablolar incelendiğinde NSGA2 algoritmasında bazı metrik değerlerinin hesaplanamadığı görülmektedir. Buna karşın en yüksek metrik değerleri hem eğitimde hem de çapraz doğrulamada FURIA algoritması kullanıldığında hesaplanmıştır. Bu durum bu algoritmanın diğer algoritmalarından daha başarılı olduğu şeklinde yorumlanabilir. Sınıflandırmalarda en yüksek Kappa değeri eğitimde 0.87, doğrulamada ise 0.72 olarak hesaplanmıştır

Çizelge 1: Eğitim sonrası sınıflandırma ölçütleri

FLR								
Sınıf	DP Oranı	YP Oranı	Kesinlik	Duyarlılık	F-Skoru	MCC	AUC	Kappa
Volkanitler	1	0	1	1	1	1	1	
Arkoz	1	0	1	1	1	1	1	
Kumtaşı	1	0.42	0.76	1	0.86	0.66	0.78	0.66
Kireçtaşı	0.27	0	1	0.22	0.37	0.43	0.61	
Ortalama	0.82	0.24	0.86	0.82	0.77	0.67	0.78	
FURIA								
Sınıf	DP Oranı	YP Oranı	Kesinlik	Duyarlılık	F-Skoru	MCC	AUC	Kappa
Volkanitler	1	0	1	1	1	1	1	
Arkoz	1	0.1	0.88	1	0.94	0.93	1	
Kumtaşı	0.94	0.07	0.94	0.94	0.94	0.87	0.94	0.87
Kireçtaşı	0.81	0.04	0.85	0.81	0.83	0.79	0.91	
Ortalama	0.92	0.05	0.92	0.92	0.92	0.87	0.94	
ENORA								
Sınıf	DP Oranı	YP Oranı	Kesinlik	Duyarlılık	F-Skoru	MCC	AUC	Kappa
Volkanitler	1	0.03	0.76	1	0.87	0.86	0.98	
Arkoz	1	0.02	0.8	1	0.88	0.88	.098	
Kumtaşı	0.80	0.15	0.88	0.80	0.84	0.64	0.82	0.67
Kireçtaşı	0.63	0.10	0.63	0.63	0.63	0.52	0.76	
Ortalama	0.80	0.11	0.80	0.80	0.80	0.66	0.84	
NSGA2								
Sınıf	DP Oranı	YP Oranı	Kesinlik	Duyarlılık	F-Skoru	MCC	AUC	Kappa
Volkanitler	0	0	--	0	--	--	0.50	
Arkoz	1	0.02	0.80	1	0.88	0.88	0.98	
Kumtaşı	0.94	0.10	0.93	0.94	0.93	0.85	0.92	0.67
Kireçtaşı	0.77	0.16	0.58	0.77	0.66	0.55	0.80	
Ortalama	0.81	0.07	--	0.81	--	--	0.85	

Çizelge 2: 10-kat çapraz doğrulama sonrası sınıflandırma ölçütleri

FLR								
Sınıf	DP Oranı	YP Oranı	Kesinlik	Duyarlılık	F-Skoru	MCC	AUC	Kappa
Volkanitler	0.9	0.01	0.9	0.9	0.9	0.88	0.94	0.37
Arkoz	0	0	--	0	--	--	0.50	
Kumtaşı	0.98	0.67	0.67	0.98	0.79	0.42	0.65	
Kireçtaşı	0.13	0.01	0.75	0.13	0.23	0.25	0.56	
Ortalama	0.69	0.39	--	0.69	--	--	0.65	
FURIA								
Sınıf	DP Oranı	YP Oranı	Kesinlik	Duyarlılık	F-Skoru	MCC	AUC	Kappa
Volkanitler	0.9	0.02	0.81	0.90	0.85	0.84	0.99	0.72
Arkoz	0.62	0.01	0.83	0.62	0.71	0.70	0.86	
Kumtaşı	0.92	0.20	0.86	0.92	0.89	0.74	0.88	
Kireçtaşı	0.68	0.05	0.78	0.68	0.73	0.66	0.84	
Ortalama	0.84	0.13	0.84	0.84	0.83	0.73	0.88	
ENORA								
Sınıf	DP Oranı	YP Oranı	Kesinlik	Duyarlılık	F-Skoru	MCC	AUC	Kappa
Volkanitler	0.9	0.02	0.81	0.90	0.85	0.84	0.93	0.50
Arkoz	0.37	0.02	0.60	0.37	0.46	0.43	0.67	
Kumtaşı	0.83	0.32	0.78	0.83	0.81	0.52	0.75	
Kireçtaşı	0.45	0.13	0.5	0.45	0.47	0.33	0.66	
Ortalama	0.71	0.22	0.70	0.71	0.71	0.50	0.74	
NSGA2								
Sınıf	DP Oranı	YP Oranı	Kesinlik	Duyarlılık	F-Skoru	MCC	AUC	Kappa
Volkanitler	0.90	0.03	0.75	0.90	0.81	0.79	0.93	0.58
Arkoz	0.50	0	1	0.50	0.66	0.69	0.75	
Kumtaşı	0.91	0.35	0.78	0.91	0.84	0.59	0.78	
Kireçtaşı	0.45	0.06	0.66	0.45	0.54	0.44	0.69	
Ortalama	0.77	0.22	0.77	0.77	0.75	0.58	0.77	

Veri setindeki dengesizliği gidermek için yapılan Smoote işlemi sonrasında çapraz doğrulama yapılmış ve karışıklık matrisi Şekil 3'te diğer metrik değerleri ise Çizelge 3'te verilmiştir.


		FLR				FURIA					
		Tahmin edilen				Tahmin edilen					
FLR	Gerçek		Volkanitler	Arkoz	Kumtaşı	Kireçtaşı		Volkanitler	Arkoz	Kumtaşı	Kireçtaşı
		Volkanitler	60	0	0	0	Volkanitler	60	0	0	0
		Arkoz	0	35	21	0	Arkoz	0	56	0	0
		Kumtaşı	1	0	39	16	Kumtaşı	1	0	49	6
		Kireçtaşı	0	0	15	40	Kireçtaşı	0	1	6	48
		ENORA				NSGA2					
		Tahmin edilen				Tahmin edilen					
FURIA	Gerçek		Volkanitler	Arkoz	Kumtaşı	Kireçtaşı		Volkanitler	Arkoz	Kumtaşı	Kireçtaşı
		Volkanitler	60	0	0	0	Volkanitler	60	0	0	0
		Arkoz	0	56	0	0	Arkoz	0	54	2	0
		Kumtaşı	2	5	25	24	Kumtaşı	4	2	38	12
		Kireçtaşı	2	0	6	47	Kireçtaşı	2	1	4	48

Şekil 3.Smote ve Çapraz doğrulama sonrası karmaşıklık matrisi

Çizelge 3: Smote ve 10-kat çapraz doğrulama sonrası sınıflandırma metrikleri

.FLR								
Sınıf	DP Oranı	YP Oranı	Kesinlik	Duyarlılık	F-Skoru	MCC	AUC	Kappa
Volkanitler	1	0	0.98	1	0.99	0.98	0.99	
Arkoz	0.62	0	1	0.62	0.76	0.74	0.81	
Kumtaşı	0.69	0.21	0.52	0.69	0.59	0.44	0.74	0.68
Kireçtaşı	0.72	0.09	0.71	0.72	0.72	0.63	0.81	
Ortalama	0.76	0.07	0.80	0.76	0.77	0.70	0.84	
FURIA								
Sınıf	TP Rate	FP Rate	Kesinlik	Duyarlılık	F-Skoru	MCC	AUC	Kappa
Volkanitler	1	0	0.98	1	0.99	0.98	0.99	
Arkoz	1	0	0.98	1	0.99	0.98	1	
Kumtaşı	0.87	0.03	0.89	0.87	0.88	0.84	0.93	0.91
Kireçtaşı	0.87	0.03	0.88	0.87	0.88	0.84	0.94	
Ortalama	0.93	0.02	0.93	0.93	0.93	0.91	0.96	
ENORA								
Sınıf	TP Rate	FP Rate	Kesinlik	Duyarlılık	F-Skoru	MCC	AUC	Kappa
Volkanitler	1	0.02	0.93	1	0.96	0.95	0.98	
Arkoz	1	0.02	0.91	1	0.95	0.94	0.98	
Kumtaşı	0.44	0.03	0.80	0.44	0.57	0.51	0.70	0.77
Kireçtaşı	0.85	0.14	0.66	0.85	0.74	0.66	0.85	
Ortalama	0.82	0.05	0.83	0.82	0.81	0.77	0.88	
NSGA2								
Sınıf	TP Rate	FP Rate	Kesinlik	Duyarlılık	F-Skoru	MCC	AUC	Kappa
Volkanitler	1	0.03	0.90	1	0.95	0.93	0.98	
Arkoz	0.96	0.01	0.94	0.96	0.95	0.94	0.97	
Kumtaşı	0.67	0.03	0.86	0.67	0.76	0.70	0.82	0.84
Kireçtaşı	0.87	0.07	0.80	0.87	0.83	0.78	0.90	
Ortalama	0.88	0.03	0.88	0.88	0.87	0.84	0.92	

Sonuçlar incelendiğinde smote işleminin algoritmaların hesaplanan metrik değerlerini arttırdığı görülmektedir. Kappa değeri 0.91'e kadar yükselmiştir. Algoritmaların SMOTE işlemi öncesi ve sonrası elde edilen doğruluk ve hata değerleri Şekil 4'te verilmiştir.

**Şekil 4.** Algoritmaların a) doğruluk b) Rms değerleri

4. SONUÇLAR

Dört farklı bulanık mantık algoritması kullanılarak yapılan kaya sınıflandırmalarında genel olarak algoritmalar başarılı sonuçlar vermiştir. Algoritmaların sınıflandırma başarıları hem dengesiz veride hem de dengesizlik giderildikten sonra karşılaştırılmıştır. Algoritmaların dengeli verilerde daha iyi sonuçlar verdiği görülmüştür. Algoritmalarından en başarılı olan algoritma FURIA algoritması olmuştur. Bu algoritma hem dengesiz veri setinde hem de dengeli veri seti kullanıldığında diğer algoritmalarından daha yüksek metrik değerlerine sahip olmuştur. Algoritma en yüksek doğruluk oranına sahip olmasının yanı sıra en az hata oranına ile bu sınıflandırmayı yapmıştır.

ÇIKAR ÇATIŞMASI BEYANI

Yazarlar arasında çıkar çatışması bulunmamaktadır.

YAZARLARIN KATKILARI

E.E.: Yöntem, analiz, kaynaklar, yazı yazma - orijinal taslak hazırlama.

KAYNAKLAR

- [1] Kurtuluş, C., Sertçelik, F., Sertçelik, I. Correlating physico-mechanical properties of intact rocks with P-wave velocity. *Acta Geodaetica et Geophysica*, 51, 571-582, 2016.
- [2] Ran, X., Xue, L., Zhang, Y., Liu, Z., Sang, X., He, J. Rock classification from field image patches analyzed using a deep convolutional neural network. *Mathematics*, 7(8), 755, 2019.
- [3] Su, C., Xu, S. J., Zhu, K. Y., & Zhang, X. C. Rock classification in petrographic thin section images based on concatenated convolutional neural networks. *Earth Science Informatics*, 13, 1477-1484, 2020.
- [4] dos Anjos, C. E., Avila, M. R., Vasconcelos, A. G., Pereira Neta, A. M., Medeiros, L. C., Evsukoff, A. G., .. & Landau, L. Deep learning for lithological classification of carbonate rock micro-CT, 2021.
- [5] Imamverdiyev, Y., & Sukhostat, L. Lithological facies classification using deep convolutional neural network. *Journal of Petroleum Science and Engineering*, 174, 216-228, 2019.
- [6] Chen, J., Yang, T., Zhang, D., Huang, H., & Tian, Y. Deep learning based classification of rock structure of tunnel face. *Geoscience Frontiers*, 12(1), 395-404, 2021.
- [7] Santos, A. E. M., Lana, M. S., & Pereira, T. M. Evaluation of machine learning methods for rock mass classification. *Neural Computing and Applications*, 34(6), 4633-4642, 2022.
- [8] Liu, Q., Wang, X., Huang, X., & Yin, X. Prediction model of rock mass class using classification and regression tree integrated AdaBoost algorithm based on TBM driving data. *Tunnelling and Underground Space Technology*, 106, 103595, 2020.
- [9] Hasegawa, N., Hasegawa, S., Kitaoka, T., & Ohtsu, H. Applicability of neural network in rock classification of mountain tunnel. *Materials Transactions*, 60(5), 758-764, 2019.
- [10] Bertuzzi, R. Revisiting rock classification to estimate rock mass properties. *Journal of Rock Mechanics and Geotechnical Engineering*, 11(3), 494-510, 2019.

- [11] Dai, B., Li, D., Zhang, L., Liu, Y., Zhang, Z., & Chen, S. Rock Mass Classification Method Based on Entropy Weight–TOPSIS–Grey Correlation Analysis. *Sustainability*, 14(17), 10500, 2022.
- [12] Sadeghi, S., Sharifi Teshnizi, E., & Ghoreishi, B. Correlations between various rock mass classification/characterization systems for the Zagros tunnel-W Iran. *Journal of Mountain Science*, 17(7), 1790-1806, 2020.
- [13] Lu, J., Guo, W., Liu, J., Zhao, R., Ding, Y., Shi, S. An Intelligent Advanced Classification Method for Tunnel-Surrounding Rock Mass Based on the Particle Swarm Optimization Least Squares Support Vector Machine. *Applied Sciences*, 13(4), 2068, 2023.
- [14] Huang, X., Yin, X., Liu, B., Ding, Z., Zhang, C., Jing, B., & Guo, X. A gray wolf optimization-based improved probabilistic neural network algorithm for surrounding rock squeezing classification in tunnel engineering. *Frontiers in Earth Science*, 10, 857463, 2022.
- [15] Amiripallia, S. S., Rao, G. N., Beharaa, J., Sanjay, K. *Mineral Rock Classification Using Convolutional Neural Network*. Recent Trends in Intensive Computing; IOS Press: Amsterdam, The Netherlands, 2021.
- [16] Afraei, S., Shahriar, K., & Madani, S. H. Developing intelligent classification models for rock burst prediction after recognizing significant predictor variables, Section 1: Literature review and data preprocessing procedure. *Tunnelling and Underground Space Technology*, 83, 324-353, 2019.
- [17] Marinos, V. A revised, geotechnical classification GSI system for tectonically disturbed heterogeneous rock masses, such as flysch. *Bulletin of Engineering Geology and the Environment*, 78, 899-912, 2019.
- [18] Alzubaidi, F., Mostaghimi, P., Si, G., Swietojanski, P., & Armstrong, R. T. Automated rock quality designation using convolutional neural networks. *Rock mechanics and rock engineering*, 55(6), 3719-3734, 2022.
- [19] Alzubaidi, F., Mostaghimi, P., Swietojanski, P., Clark, S. R., & Armstrong, R. T. Automated lithology classification from drill core images using convolutional neural networks. *Journal of Petroleum Science and Engineering*, 197, 107933, 2021.
- [20] de Freitas, K. L. F., da Silva, P. N., Faria, B. M., Gonçalves, E. C., Rios, E. H., Nobre-Lopes, J., ... & de Vasconcelos Azeredo, R. B. A data mining approach for automatic classification of rock permeability. *Journal of Applied Geophysics*, 196, 104514, 2022.
- [21] Alférez, G. H., Vázquez, E. L., Ardila, A. M. M., & Clausen, B. L. Automatic classification of plutonic rocks with deep learning. *Applied Computing and Geosciences*, 10, 100061, 2021.
- [22] Deng, G., & Fu, Y. Fuzzy rule based classification method of surrounding rock stability of coal roadway using artificial intelligence algorithm. *Journal of Intelligent & Fuzzy Systems*, 40(4), 8163-8171, 2021.
- [23] Taheri, F., Jafari, H., Rezaei, M., & Bagheri, R. The use of continuous fuzzy and traditional classification models for groundwater potentiality mapping in areas underlain by granitic hard-rock aquifers. *Environmental Earth Sciences*, 79, 1-16, 2020.
- [24] Stehliková, B., Bogdanovská, G., Flegner, P., Frančáková, R., & Drančák, L. *Rock Classification Using a Vibration Signal in the Process of Rotary Drilling*, 2023.
- [25] Chawla, N. vd. SMOTE: Synthetic minority over-sampling technique. *Journal of Artificial Intelligence Research*, 16, 321-357, 2002.
- [26] Hühn, J., Hüllermeier, E. FURIA: an algorithm for unordered fuzzy rule induction. *Data Mining and Knowledge Discovery*, Volume 19, Issue 3, p. 293–319, 2009.
- [27] V. G. Kaburlasos, I. N. Athanasiadis, P. A. Mitkas . Fuzzy Lattice Reasoning (FLR) Classifier and its Application for Ambient Ozone Estimation. *International Journal of Approximate Reasoning*, Volume 45, Issue 1, May 2007,152-188, 2003.
- [28] Jimenez, F., Sanchez, G. & Juarez, J.M. Multi-objective Evolutionary Algorithms for Fuzzy Classification in Survival Prediction. *Artificial Intelligence in Medicine*, 60(3), 197-219, 2014.