



Evrişimli sinir ağları kullanılarak ince kesit görüntülerden hidrotermal alterasyon türlerinin sınıflandırılması

Classification of hydrothermal alteration types from thin section images using convolutional neural networks

Rıza Çenet¹ , Emre Ünsal^{2,*} , Oktay Canbaz³ 

¹ Sivas Cumhuriyet Üniversitesi, Fen Bilimleri Enstitüsü., 58140, Sivas, Türkiye

² Sivas Cumhuriyet Üniversitesi, Yazılım Mühendisliği Bölümü, 58140, Sivas, Türkiye

³ Sivas Cumhuriyet Üniversitesi, Jeoloji Mühendisliği Bölümü, 58140, Sivas, Türkiye

Öz

Hidrotermal alterasyon, değerli madenlerin arama aşamalarında kullanılan önemli bir jeolojik özelliktir. Bu araştırma, mikroskop görüntülerinde hidrotermal alterasyon türlerini tanımlamak için oluşturulan iki farklı derin öğrenme ağı yapısına odaklanmaktadır. 2500 görüntüden oluşan veri setinin, %70'i ağı eğitilmesinde, %20'si ağı test edilmesinde ve %10'u ağı geçerliliğinin ölçülmesinde kullanılmıştır. Evrişimli Sinir Ağı (ESA) ve Xception modelleri, Adam, RMSprop ve SGD optimizasyon fonksiyonları kullanılarak eğitilmiş ve sonuçları karşılaştırılmıştır. ESA modeli için Adam ve SGD optimizasyon fonksiyonları %96 doğru sınıflandırma yaparak, en başarılı sınıflandırmayı gerçekleştirmiştir. Xception modeli için en yüksek doğruluk değeri %98 ile Adam ve RMSprop optimizasyon fonksiyonları kullanılan ağlarda gerçekleşmiştir. Her ne kadar Xception modeli daha yüksek doğruluk değerlerine sahip olsa da ağı eğitimi süresi göz önüne alındığında ESA modelinin işlemi çok daha hızlı tamamladığı görülmüştür.

Anahtar kelimeler: Hidrotermal alterasyon, İnce kesit, Derin öğrenme, CNN, Sınıflandırma

1 Giriş

Makine öğrenmesi ve derin öğrenme modelleri, günümüzde gelişen bilgisayar teknolojisinin önemli çalışma alanları içerisinde yer almaktadır. Makine öğrenmesinin en çok kullanılan alanlarından bir tanesi nesne tanımlama ve sınıflandırmadır. Tanıma veya sınıflandırma işlemi nesnelerin renk, doku veya boyut gibi ayırt edici özellikleri kullanılarak gerçekleştirilir. Bir nesnenin hangi özelliğinin önemli olduğunu belirlenmesi ve ona göre ayarlanma yapılması oldukça zahmetli bir süreçtir. Ayrıca bir nesne için önemli olan özelliklere göre tasarlanan öğrenme ağı başka bir nesne için işe yaramaz. Tang vd. [1] Evrişimli Sinir Ağı (ESA)'nda, nesnelerin önemli özelliklerini bir insanın belirlemesine ihtiyaç duymadan, ağı kendisi belirlemektedir. Bu da bütün nesneler için ek ayarlamalara gerek kalmadan belli bir modelin kullanılmasına olanak sağlar. Bu sayede ESA, çok büyük verilerde ve farklı disiplinlerde, yüksek doğruluk oranları ile sınıflandırma

Abstract

Hydrothermal alteration is an important geological feature used in the exploration stages of precious minerals. This research focuses on two distinct deep-learning network structures created to identify hydrothermal alteration types in microscope images. A dataset of 2500 images, 70% of this data set was used to train, 20% to test, and 10% to measure the validity of the network. Convolutional Neural Network (CNN) and Xception models were trained using Adam, RMSprop and SGD optimization functions and the results are discussed. The Adam and SGD optimization functions for the CNN model performed the most successful classification with 96% accuracy. In the case of the Xception model, the highest accuracy value was 98% for the networks using the Adam and RMSprop optimization functions. Although the Xception model had higher accuracy values, it was observed that the CNN model completed the process significantly faster considering the training time of the network.

Keywords: Hydrothermal alteration, Thin section, Deep learning, CNN, Classification

yapabilir. ESA'nın bu özellikleri sayesinde farklı çalışma alanlarında yüksek doğrulukta öğrenme değerleri elde edilebilmektedir. Son yıllarda literatürde yer bilimlere [2], [3] ve sağlık alanı [4], [5] gibi farklı disiplinlerde çeşitli çalışmalarda makine öğrenmesi ve derin ağlar kullanılarak başarılı sonuçlar elde edilmektedir.

Değerli metalik/metalik olmayan maden yatakları ülke ekonomileri için önemli katkı sağlamaktadırlar. Bu çalışma, maden yataklarının keşfinde önemli adımlardan bir tanesini oluşturan hidrotermal alterasyonları konu almaktadır. Bu alterasyonlar, sıcak sulu çözeltilerin değişen fiziko-kimyasal koşullar altında geçtikleri kayalarla etkileşimi, mineralojik, kimyasal ve dokusal değişiklikleri içeren karmaşık bir süreç olan hidrotermal alterasyon zonlarının gelişimiyle sonuçlanır [6]. Hidrotermal alterasyon, yer kabuğunun derinliklerinde gömülü olan porfiri tip, düşük ve yüksek sülfidasyonlu epitermal altın yatakları gibi değerli metaller ve baz metaller içeren büyük hidrotermal maden yataklarının tespitinde önemli adımlardan bir tanesini oluşturmaktadır.

* Sorumlu yazar / Corresponding author, e-posta / e-mail: eunsal@cumhuriyet.edu.tr

Geliş / Received: 13.09.2023 Kabul / Accepted: 24.01.2024 Yayınlanma / Published: 15.04.2024

doi: 10.28948/ngumuh.1359664

Özellikle altın, kurşun, çinko ve bakır gibi baz metalleri içeren hidrotermal yataklardan üretilen bu metallerin sürekli üretimini garanti altına almak için yeni yatakların keşfedilmesi, araştırılması ve ekonomiye kazandırılması gerekmektedir.

Epidotlaşma, karbonatlaşma, kloritleşme, serizitleşme, silisleşme ve killeşme hidrotermal sistemlerde en yoğun gözlenen hidrotermal alterasyon türlerindedir. Bu alterasyon türlerinin tanımlanması için petrografik incelemelere ve jeokimyasal analizlere gereksinim duyulur. Saha çalışmaları sırasında toplanan temsili hidrotermal alterasyon örnekleri, petrografik incelemeler için ince kesit hazırlama ve jeokimyasal analizler için ise toz numune hazırlama işlemlerine tabi tutulur. Petrografik incelemelerde yoğun alterasyona uğramış ve mineral tayini yapılamayan kayaç örneklerinde tanımlamalar, jeokimyasal analiz yöntemleri ile gerçekleştirilir. İnce kesitlerde hidrotermal alterasyon türlerinin belirlenebilmesi için uzun süreçlere ve hidrotermal alterasyon alanında uzman araştırmacılara ihtiyaç duyulur. Ancak son yıllarda, veri seti olarak ince kesit görüntüleri kullanılarak gerçekleştirilen bilgisayar uygulamaları kayaç türü belirleme ve/veya sınıflama da başarılı sonuçlar elde etmeye başlamıştır. Bu çalışmalara ait bazı örnekler aşağıda verilmiştir.

Polat vd. [7] altı farklı volkanik kayaca ait 1200 ince kesit görüntüsü bulunduran veri setini, oluşturdukları derin öğrenme ağını dört farklı optimizasyon fonksiyonu ile ayrı ayrı eğiterek volkanik kayaç sınıflandırması yapmışlardır. Araştırmacılar bu çalışmada, az altere/altere olmamış volkanik kayaçlara ait temsili ince kesit görüntülerinde çalışmayı gerçekleştirmişlerdir. Rubo vd. [8] beş farklı model oluşturarak sedimanter kayaçlara ait ince kesit görüntüleri üzerinde kalsit, dolomit, kuvars, kil, opak mineralleri ve ince kesitteki boşlukları sınıflandırmaya yönelik çalışma gerçekleştirmişlerdir. Bu modellerden ikisi yapay sinir ağları ile oluşturulmuşken diğer üçünde random forest algoritması kullanılmıştır. Lima ve Duarte [9], çamurtaşlarının petrografik sınıflandırmasında kullanılmak üzere, 5 farklı sondaj karotundan alınan örneklerle ait 98 ince kesitten mikroskop altında 2.5 ve 10 yakınlaştırma oranı kullanılarak 513 tane görüntü elde etmişlerdir. Bu görüntüleri dört sınıfa ayırarak evrişimli sinir ağı ile sınıflandırma yapmışlardır. Guojian ve Peisong [10], feldispat kumtaşlarının, tane boylarına göre sınıflandırmasını yapmak için, kayaçlardan elde ettikleri 10000 ince kesitin 8000 kadarını ağı eğitimi için, 2000 tanesini ağı testinde kullanarak ResNet50 ve ResNet101 transfer öğrenme modellerini eğitip %90.24 ve %91.63 doğruluklarla sınıflandırma elde etmişlerdir. Xu vd. [11], metamorfik, volkanik ve sedimanter (kırıntılı/karbonat) kayaç gruplarına ait 8882 ince kesit görüntüsünün %20'sini test için kullanmıştır. Bu görüntülerin bazıları ortogonal ışık altında diğerleri tek nikol ışık altında elde edilmiştir. Çalışmalarında ResNet-18 kullanarak bir sınıflandırma yapmışlardır. Zhang vd. [12] Petrografik ince kesit görüntü veri bankasından (Science Data Bank) elde ettikleri sedimanter ve metamorfik kayaçlardan oluşan 12 farklı kayaca ait ince kesit görüntülerinden 20242 görüntü oluşturmuşlardır. Kendi geliştirdikleri derin öğrenme ağı (PD-RSBU-CW)

sınıflandırma gerçekleştirmişlerdir. Iglesias vd. [13] demir cevherinin bileşim analizinde benzer yansımalara sahip olan reçine ve kuvars fazının ayırt edilmesine yönelik 1747 reçine ve 1745 kuvars görüntüsünden veri setlerini oluşturup her sınıf için 442 görüntüyü test için kullanmışlardır. ESA ile yapılan sınıflandırmada %95'in üzerinde doğruluk elde etmişlerdir. Bérubé vd. [14] Kanada'nın Pontiac Bölgesi'nden 570 adet meta-sedimanter (160'ı altere olmuş), 122 adet mafik dayk (52'si altere olmuş), 113 adet felsik orta intrüzif (47'si altere olmuş) olmak üzere toplam 819 tane kayaç örneği toplamışlardır. Bu kayaçları tane yoğunlukları ve manyetik duyarlılıklarına göre sınıflandırmak için makine öğrenmesi yöntemleri olan; K-En Yakın Komşu (KNN), Destek Vektör Makineleri (SVM), Doğrusal Diskriminant Analizi (LDA), Rastgele Orman (RF) ve Naive Bayesian (NB) algoritmaları kullanılmıştır. SVM ve KNN algoritmaları diğer üç algoritmadan daha başarılı sınıflandırma yapmıştır. SVM algoritması meta-sedimanter için %73, mafik dayk için %93 ve felsik-orta intrüzif sınıfı için %69 f1 skoru üretmiştir.

Bu çalışmada, arazi çalışmaları kapsamında toplanan tamamen altere olmuş granitoyit ve volkanik kayaçlardan elde edilmiş olan ince kesit görüntüleri kullanılmıştır. Kayaç türleri belirlemede altere olmamış ve/veya az altere örneklerin tercih edilmesi gerekmektedir. Bu örneklerde, minerallerin yapısal ve dokusal özellikleri bozulmamış ve kompleks bir yapıda olmadıkları için tanımlamaları çıplak gözle bile kolaylıkla yapılabilmektedir. Nitekim yukarıda bahsedilen çalışmalarda (Bérubé vd. [14] hariç) genellikle kayaç türleri tespitine yönelik gerçekleştirilmiştir. Bérubé vd. [14] ise, altere olmamış kayaçlar ile altere olmuş kayaçları sınıflandırmaya yönelik bir çalışma gerçekleştirmiştir. İntrüzif ve volkanik kayaçların alterasyonu sonrasında benzer alterasyon mineralleri her iki kayaç sınıfında da gözlenebilir. Alterasyon yoğunluğu kayaç türü tespitini zorlaştırmakta bazı zamanlarda ise imkansız kılabilir. Bu nedenle, bu kayaçlara ait altere örnekler, altere olmamış örneklere göre farklı boyutlarda, kompleks ve grift yapıda mineralleri içerebilmektedir. Bunun sonucunda, her alterasyon türü de farklı görsel özellik (renk, yansıma, boyut vb.) gösterebilmektedir. Bu özellikleri nedeniyle bu çalışmada kullanılan altere örneklere ait ince kesit görüntüleri, yukarıda bahsedilen çalışmalarda kullanılan ince kesit görüntülerinden ayrılmaktadır. Ayrıca, çalışmada kullanılan ESA modeli, transfer öğrenme uygulamalarında kullanılan derin ağlar ile kıyaslandığında daha düşük donanımına sahip bilgisayarlarla ve daha kısa sürede eğitim işlemini sonuçlandırma kapasitesine sahip olabilmektedir. Bu nedenle, veri setinin nispeten küçük olduğu problemlerde hesaplama maliyetini azaltmak ve eğitim sürelerini kısaltmak için önerilen model kullanılmıştır.

Çalışma kapsamında elde edilen 2500 adet ince kesit hidrotermal alterasyon görüntüsü kullanılarak 5 farklı alterasyon türünü ESA yardımıyla sınıflandırmaya çalışılmış, elde edilen sonuçlar aynı veri setinin Xception modeli ile eğitilmesi sonucu elde edilen sonuçlar ile kıyaslanmıştır.

2 Materyal ve Metot


2.1. Derin öğrenme

Derin öğrenme, makine öğrenmesinin en çok tercih edilen alt dallarından bir tanesidir. Derin öğrenmeyi makine öğrenmesinin ötesine taşıyan durum, çok büyük veri setlerinin tanımlanması ve sınıflandırılmasında çok daha iyi sonuçlar üretebilmesidir [15]. Geleneksel makine öğrenimi yöntemleri kullanıcı tarafından birçok manuel ayarlama gerektirirken, derin öğrenmenin en büyük avantajlarından biri, sinir ağlarının daha önce görünür olmayan verilerden gizli öznelikleri ve ilişkileri ortaya çıkarabilme kabiliyetidir. Böylece kullanıcılara zaman ve enerji tasarrufu sağlayarak, büyük veri kümelerinde daha yüksek başarımlar elde edilmesine olanak tanır. Bu çalışmada, özellikle görüntü sınıflandırılması problemlerinde sıklıkla tercih edilen, ESA modeli oluşturularak, tanımlama ve sınıflandırma için kullanılmıştır.

2.2. Evrişimli sinir ağı

ESA'nın yapısı insan beyninden ilham alınarak tasarlanmıştır. Böylece ESA'nın işlem döngüsü, insan beyninin yapısını ve işlevini keşfederek kendi yapısını sürekli geliştirebilir [16]. ESA mimarisi çeşitli katmanların bir araya gelmesinden oluşmaktadır. Bölümlerde, konvolüsyon ve maksimum ortaklama katmanları vardır. Konvolüsyon katmanında nesnelere özellik haritaları çıkarılarak, ağırlıkları hesaplanır ve bir dizine kaydedilir. Bu dizi aracılığıyla bir önceki katmanın özellik haritasındaki yerel parçalarla bağlanma gerçekleştirilir. Elde edilen yerel ağırlıkların toplamı düzeltilmiş doğrusal birim katmanından (ReLU) geçirilir. Maksimum ortaklama katmanı ise belirlenen boyuttaki filtreler ile özellik haritasındaki yerel parçaların maksimumunu alarak, bu değeri parçadaki değerlerin yerine geçecek şekilde bir atama yapar. Bu filtreler, filtre boyutunda kaydırılarak tüm özellik haritasında gezdirilir. Böylelikle ana şekil üzerinde çok bir bozulma ve değişim olmadan, boyut indirgeme yapılmış olur. Konvolüsyon katmanı takibinde ReLU fonksiyonu ve sonra da maksimum ortaklama katmanı kümesine, bir konvolüsyon bloğu (bölümü) denir. ESA, birçok konvolüsyon bölümünden ve sonunda tam bağlantı katmanından oluşmaktadır. Bu çalışmada oluşturulan ESA yapısı dört konvolüsyon bloğundan oluşmaktadır. İlk üç bölüm yukarıda bahsedildiği gibi konvolüsyon katmanı, ReLU katmanı ve maksimum ortaklama katmanından oluşmaktadır.

Giriş katmanında resimler boyut olarak küçültülerek 144x108 boyutlarına indirgenmiştir. Geliştirilen ESA modeli içerisinde, birinci ve ikinci konvolüsyon katmanlarında 3x3 boyutlarında 32 filtre, üçüncü katmanda aynı boyutlarda 64 filtre kullanılmıştır. Bu filtreler görüntü üzerinde, (1, 1) atlama miktarı ile çalıştırılmıştır. Maksimum ortaklama katmanında, 2x2 lik filtreler kullanılmıştır. Son katman, tam bağlantılı katman olup, sınıflandırmanın yapıldığı katmandır. Bu katmanda 128 filtre bulunup aktivasyon fonksiyonu olarak "softmax" kullanılmıştır. Oluşturulan derin öğrenme ağının yapısı Şekil 1'de gösterilmiştir. Bu ağ, Adam, RMSprop, ve SGD optimizasyon fonksiyonları ile ayrı ayrı çalıştırılarak, sınıflandırma sonuçları elde edilmiştir.



Şekil 1. Evrişimli sinir ağı mimarisi

Optimizasyon fonksiyonlarının amacı, bir problemin çözümü için en uygun değişkenleri kullanarak, modelin en uygun sonuçları kullanmasını sağlamaktır. Bahsi geçen en uygun sonuç, bir işlem sonucu çıkan sonuçları maksimize ya da minimize edilmesini sağlayan fonksiyonlar ile bulunur. Bu işlemi yapan fonksiyonlara amaç fonksiyonları denir [17]. Bu sebeple optimizasyon fonksiyonları birçok mühendislik alanında kullanılmaktadır [18]. ESA'da optimizasyon fonksiyonlarının amacı kayıp fonksiyonun sonuçlarını minimize ederek modelin sınıflandırma işlemlerinde kullandığı ağırlıkları ve öğrenme oranları en uygun duruma getirmektir [19]. ESA'da ağırlıkların güncellenmesi için farklı optimizasyon fonksiyonları kullanılır ve bu güncellemeler geriye yayılım algoritması ile yapılır [20]. Kullanılan optimizasyon fonksiyonların çoğu SGD gibi stokastik amaç fonksiyonlarına sahiptir. SGD'de ağırlık hesaplamasında tüm gradyanları kullanmak yerine rastgele seçilenler üzerinden ağırlık hesaplaması yapılmaktadır. RMSprop eğitim sürecinde karşılaşılan sabit öğrenme katsayısı problemini çözmek için momentumlu gradyanların karesini almaktadır [21]. Adam optimizasyon fonksiyonu adı "Adaptif moment tahmini" anlamına gelmektedir. Adam, AdaGrad ve RMSprop optimizasyon fonksiyonlarının avantajlarını birleştirmek üzere


tasarlanmıştır. Adam birinci dereceden gradyanlar ile işlem gerektiren stokastik bir optimizasyon fonksiyonudur. Böylelikle uygulaması kolay, bellek gereksinimi az ve hesaplama için verimlidir [22].

Bu çalışmada, SGD optimizasyon fonksiyonu, öğrenme oranı (LR) 0,001 olarak seçilmiştir. Adam optimizasyon fonksiyonu için, öğrenme oranı 0,0001 olarak belirlenmiştir. RMSprop optimizasyon fonksiyonu ise 2×10^{-5} öğrenme oranı çalıştırılmıştır. Her bir eğitimin, simülasyon sonuçları kaydedilerek, sonuç bölümünde karşılaştırması yapılmıştır.

Kullanılan derin öğrenme modelleri, python programlama dili ile, tensorflow ve keras kütüphaneleri kullanılarak oluşturulmuştur. Bu model, Intel Core i7 10700KF işlemci, NVIDIA GeForce RTX 3060 16GB model ekran kartı ve 64GB ram kapasitesine sahip Windows işletim sistemli bir bilgisayarda eğitilmiştir.

2.3. Veri seti

Bu çalışmada petrografik olarak tanımlanan alterasyon tiplerinin ince kesitleri Sivas Cumhuriyet Üniversitesi Jeoloji Mühendisliği Laboratuvarında hazırlanmış ve incelenmiştir. Alterasyon tiplerinin fotomikrografları için Leica DM 2500 polarize mikroskop kullanılmıştır. Her bir değişiklik türü için 1728x1296 piksel boyutunda 500'er adet olmak üzere toplam 2500 mikrogram elde edilmiştir (Şekil 2).



Şekil 2. Kullanılan mikroskop sistemi ve alterasyon türlerine ait temsili ince kesit görüntüleri (a) Leica Dm-2500p polarize mikroskop, (b) epidotlaşma, (c) kloritleşme, (d) karbonatlaşma, (e) serizitleşme, (f) silisleşme

Oluşturulan veri setinin %70'i ağız eğitilmesinde, %20'si ağız test edilmesinde ve kalanı da ağız geçerliliğinin kontrol edilmesinde kullanılmıştır. Ağız eğitilmesi sırasında işlem hacminin azalması için girdilerin boyutları 144x108 piksel boyutlarına indirgenmiştir.

2.4. Karışıklık matrisi

Sınıflandırma yapılan modellerin, başarısını etkili bir şekilde değerlendirmek için karışıklık matrisinden faydalanılmaktadır [23]. Karışıklık matrisi satır ve sütunlardan oluşmaktadır. Satırlar tahmin sınıflarını ifade ederken, sütunlar gerçek sınıflarını göstermektedir. Örnek bir karışıklık matrisi yapısı Tablo 1'de gösterilmiştir. Bu

tabloda doğru şekilde sınıflandırılan pozitif ve negatif değerler sırasıyla TP ve TN ile gösterilirken, yanlış bir şekilde sınıflandırılan pozitif ve negatif değerler sırasıyla FP ve FN ile gösterilmiştir. Karışıklık matrisindeki veriler, sınıflandırmanın başarısının ölçülmesinde, etkili sonuçlar vermektedir [24].

Tablo 1. Karışıklık matrisi yapısı

	Tahmin Edilen Pozitif Değer(+)	Tahmin Edilen Negatif Değer(-)
Gerçek Pozitif Değer(+)	TP	FN
Gerçek Negatif Değer(-)	FP	TN

2.5. Performans karşılaştırma ölçütleri

Tüm optimizasyon fonksiyonları ile çalıştırılan ESA'nın sınıflandırma başarısı, karışıklık matrisi (confusion matrix), doğruluk (accuracy), kesinlik skoru (precision-p), duyarlılık skoru (recall-r) ve f1-skor metriklerine göre değerlendirilmiştir. Bu metriklerin kullandığı bağıntılar sırasıyla aşağıdaki, Denklem (1, 2, 3, 4)'de verilmiştir [24].

$$\text{Doğruluk(Accuracy)} = \frac{TP + TN}{TP + TN + FP + FN} \quad (1)$$

$$\text{Kesinlik(Precision - p)} = \frac{TP}{TP + FP} \quad (2)$$

$$\text{Duyarlılık Skoru(Recall - r)} = \frac{TP}{TP + FN} \quad (3)$$

$$f1 - \text{skor} = 2 \times \frac{p \times r}{p + r} \quad (4)$$

3 Bulgular ve tartışma

Hazırlanan veri seti üzerinde hidrotermal alterasyon tiplerin tespiti ve sınıflandırılması için bu çalışmada iki farklı derin öğrenme modeli kullanılmıştır. Bu çalışmada önerilen ESA modeli ve literatürde yaygın olarak kullanılan Xception modeli [25] ile oluşturulan ağlar veri seti üzerinde eğitilerek kullanılmıştır. Her iki modelde de tüm optimizasyon fonksiyonları için yığın boyutu (batch-size) 25, bölüm değeri (epoch) 50 olarak belirlenmiştir.

3.1 ESA modeli simülasyon sonuçları


Belirlenen parametreler ile eğitilmiş ESA'lara ait sonuçlar bu bölüm içerisinde değerlendirilmiştir. Adam, RMSprop ve SGD optimizasyon fonksiyonları kullanılarak eğitilen ESA'lar, sırasıyla 128.86 sn, 133.13 sn ve 132.78 sn sürede eğitim algoritmasını başarıyla tamamlamışlardır.

Üç farklı optimizasyon fonksiyonu ile eğitilen ESA modeli için elde edilen sonuçlara ait Doğruluk ve Kayıp Grafikleri, ayrıca eğitim sonunda gerçekleşen sınıflandırma sonuçlarının analizi için Karışıklık Matrisleri ait bulgular sunulmuştur.

Doğruluk ve Kayıp Grafikleri üzerinde eğitim (train) veri setine ait eğitim sonuçları mavi renk ile, test veri setine ait sonuçlar ise turuncu renk ile gösterilmiştir. Karışıklık matrisi içerisinde doğru şekilde sınıflandırılan test veri setine ait resimler matrisin köşegeni boyunca koyu mavi kutucuk içerisinde gösterilmiştir.


3.1.1 ESA-Adam

ESA'nın Adam optimizasyon fonksiyonu ile eğitilmesi sonucu elde edilen Model Doğruluk (Accuracy) ve Model Kayıp (Loss) Grafikleri Şekil 3'te verilmiştir.



Şekil 3. Adam optimizasyon fonksiyonu ile eğitilen ağın (a) Model Doğruluk (Accuracy) ve (b) Model Kayıp (Loss) Grafikleri

Bu grafiklerde, 10. epoch değerine kadar hızlı bir öğrenme ve sonrasında 0.9 doğruluk değerinin üzerine çıkıldığında ise nispeten daha yavaş bir öğrenme gerçekleştiği eğitim sonucunda ise 0.96'lık bir doğruluk değerine erişildiği görülmektedir.



Şekil 4. Adam optimizasyon fonksiyonuna ait karışıklık matrisi

Ağın Adam optimizasyon fonksiyonu ile çalıştırılması sonucu elde edilen karışıklık matrisine göre (Şekil 4); epidotlaşma, karbonatlaşma ve serizitleşme sınıfları tamamen doğru sınıflandırılmış, kloritleşme sınıfının 9 tanesi karbonatlaşma sınıfına atanmış, silisleşme sınıfının 8 tanesi kloritleşme sınıfına atanırken, 1 tanesi karbonatlaşma sınıfına atanmıştır. Toplamda 500 tane test verisinin 482 tanesi doğru sınıfa atanırken 18 tanesi farklı sınıflara atanmıştır.

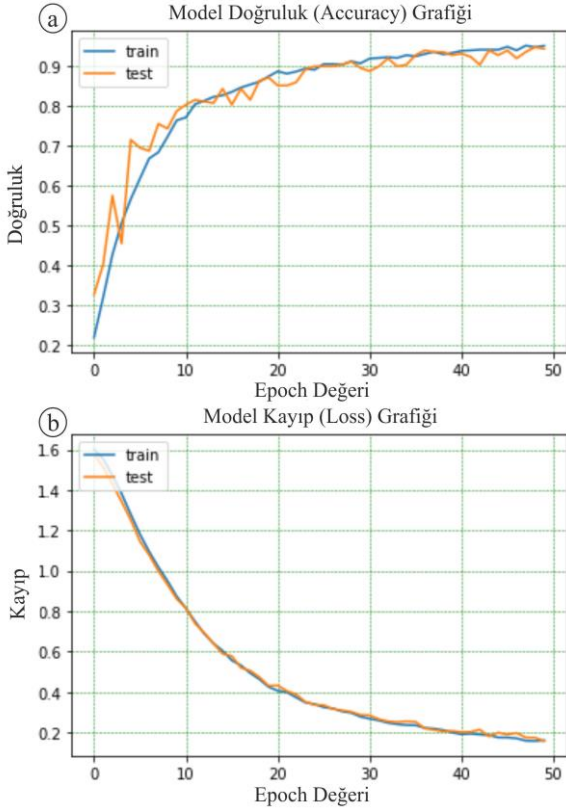
ESA'nın Adam optimizasyon fonksiyonu ile eğitilmesi sonucunda elde edilen sonuçlar Tablo 2' de gösterilmiştir.

Tablo 2. Adam optimizasyon fonksiyonuna ait sonuçlar


	precision	recall	f1-score	support
epidotlaşma	1.00	1.00	1.00	100
karbonatlaşma	0.91	1.00	0.95	100
kloritleşme	0.92	0.91	0.91	100
serizit	1.00	1.00	1.00	100
silisleşme	1.00	0.91	0.95	100
Doğruluk (accu.)			0.96	500
Makro ort.	0.97	0.96	0.96	500
Ağırlıklı ort.	0.97	0.96	0.96	500

3.1.2 ESA-RMSprop

ESA'nın RMSprop optimizasyon fonksiyonu ile eğitilmesine ait Model Doğruluk (Accuracy) ve Model Kayıp (Loss) Grafikleri Şekil 5'te gösterilmiştir. RMSprop optimizasyon fonksiyonu ile eğitilen ağın eğitim sonunda 0.94'lük bir doğruluk değerine ulaşabilmiştir.



Şekil 5. RMSprop optimizasyon fonksiyonu ile eğitilen ağın (a) Model Doğruluk (Accuracy) ve (b) Model Kayıp (Loss) grafikleri



Şekil 6. RMSprop optimizasyon fonksiyonuna ait karışıklık matrisi

Ağın RMSprop optimizasyon fonksiyonu ile eğitilmesi sonucunda elde edilen karışıklık matrisine göre (Şekil 6); serizitleşme sınıfına ait fotoğraflar tamamen doğru sınıflandırılmıştır.

Epidotlaşma sınıfına ait görüntülerden 1 tanesi kloritleşme sınıfına atanmış, karbonatlaşma sınıfının 5 tanesi kloritleşme sınıfına atanmış, kloritleşme sınıfının 11 tanesi silisleşme sınıfına atanırken 1 tanesi karbonatlaşma sınıfına atanmıştır, silisleşme sınıfının 8 tanesi kloritleşme sınıfına atanırken, 3 tanesi karbonatlaşma sınıfına atanmıştır.

Toplamda 500 tane test verisinin 471 tanesi doğru sınıfa atanırken, 29 tanesi yanlış sınıflandırılmıştır.

ESA'nın RMSprop optimizasyon fonksiyonu ile eğitilmesi sonucunda elde edilen sonuçlar Tablo 3'te gösterilmiştir.


Yapılan çalışma neticesinde en düşük doğruluk ve f1-skor değerleri sırasıyla 0.94 doğruluk ve 0.87 f1-skor ile RMSprop optimizasyon fonksiyonu ile eğitilen ESA modelinde gerçekleşmiştir.

Tablo 3. RMSprop optimizasyon fonksiyonuna ait sonuçlar

	precision	recall	f1-score	support
epidotlaşma	1.00	0.99	0.99	100
karbonatlaşma	0.96	0.95	0.95	100
kloritleşme	0.86	0.88	0.87	100
serizit	1.00	1.00	1.00	100
silisleşme	0.89	0.89	0.89	100
Doğruluk (accu.)			0.94	500
Makro ort.	0.94	0.94	0.94	500
Ağırlıklı ort.	0.94	0.94	0.94	500

3.1.3 ESA-SGD

ESA modelinin, SGD optimizasyon fonksiyonu ile eğitilmesine ait Model Doğruluk (Accuracy) ve Model Kayıp (Loss) Grafikleri Şekil 7'de gösterilmiştir.



Şekil 7. SGD optimizasyon fonksiyonu ile eğitilen ağın (a) Model Doğruluk (Accuracy) ve (b) Model Kayıp (Loss) grafikleri

SGD optimizasyon fonksiyonu ile eğitilen ağın ilk 15 epoch değeri için hızlı bir şekilde öğrendiği 0.85 doğruluk değerinin üzerine çıkılmaya başladığında ise ağın öğrenmesinin nispeten yavaşladığı gözlemlenmiştir. Adam optimizasyon fonksiyonuna kıyasla SGD'nin öğrenme performansının bu problem için daha düşük olduğu ifade edilebilir.

Bu grafiklerden yüksek doğrulukla bir öğrenme gerçekleştiği görülmekle birlikte, Adam optimizasyon fonksiyonuna göre daha yavaş bir öğrenme gerçekleştiği söylenebilir.



Şekil 8. SGD optimizasyon fonksiyonuna ait karışıklık matrisi

Ağın SGD optimizasyon fonksiyonu ile çalıştırılması ile elde edilen karışıklık matrisine göre (Şekil 8); epidotlaşma, karbonatlaşma, serizitleşme ve silisleşme sınıfları tamamen doğru sınıflandırılmıştır.

Kloritleşme sınıfının 2 tanesi karbonatlaşma, 1 tanesi epidotlaşma ve 16 tanesi silisleşme sınıfına atanmıştır. Toplamda 481 tane veri doğru şekilde sınıflandırılırken 19 tanesi ise yanlış sınıflara atanmıştır.

ESA modelinin, SGD optimizasyon fonksiyonu ile eğitilmesi sonucunda elde edilen sonuçlar Tablo 4'te gösterilmiştir.

Tablo 4. SGD optimizasyon fonksiyonuna ait sonuçlar

	precision	recall	f1-score	support
epidotlaşma	0.99	1.00	1.00	100
karbonatlaşma	0.98	1.00	0.99	100
kloritleşme	1.00	0.81	0.90	100
serizit	1.00	1.00	1.00	100
silisleşme	0.86	1.00	0.93	100
Doğruluk (accu.)			0.96	500
Makro ort.	0.97	0.96	0.96	500
Ağırlıklı ort.	0.97	0.96	0.96	500

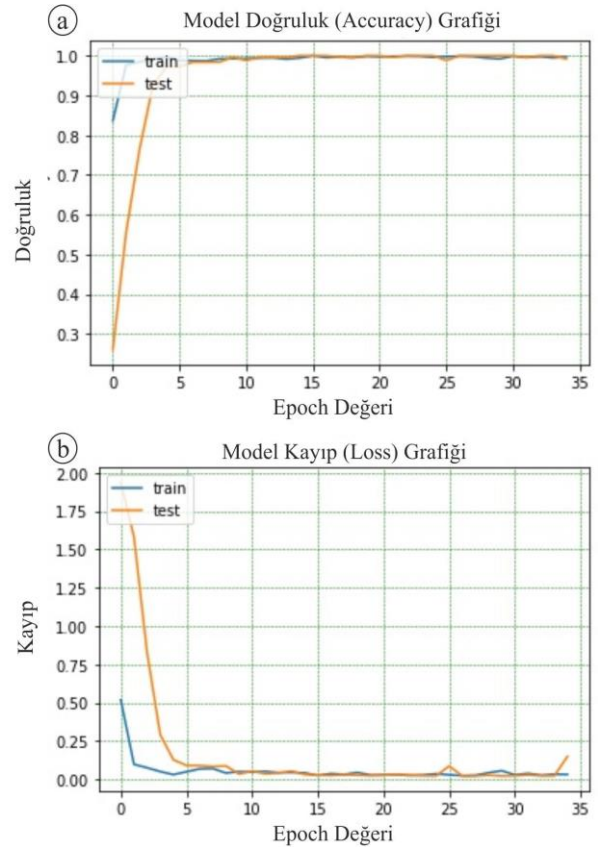
3.2 Xception ağı simülasyon sonuçları

Bu çalışma kapsamında hidrotermal alterasyon tiplerinin tespiti ve sınıflandırılması için kullanılan bir diğer derin öğrenme modeli olan Xception modeli tüm optimizasyon fonksiyonları için eğitilmiştir [25]. ESA için kullanılan yığın boyutu (batch-size) ve bölüm (epoch) değerleri sonuçların her iki model ile karşılaştırılabilmesi için aynı tutulmuştur. Xception modeline ait derin ağı Adam, RMSprop ve SGD optimizasyon fonksiyonları kullanılarak eğitilmesi sonucunda, sırasıyla 336.88 sn, 371.24 sn ve 458.93 sn sürede eğitim algoritması başarıyla tamamlamışlardır. Bu süreler bir önceki ESA modeli ile karşılaştırıldığında Xception modelinin eğitim süresinin 2.61 ile 3.45 kat daha uzun olduğu gözlemlenmiştir.

Xception modelinin üç farklı optimizasyon fonksiyonu kullanılarak eğitilmesi sonucunda elde edilen Doğruluk, Kayıp Grafikleri ve Karışıklık Matrisleri alt başlıklar içerisinde sunulmuştur.

3.2.1 Xception-Adam

Günümüzde yaygın olarak kullanılan derin öğrenme ağlarından biri olan Xception modeli ile kurulu ağı, Adam optimizasyon fonksiyonu ile eğitilmesine ait Model Doğruluk (Accuracy) ve Model Kayıp (Loss) Grafikleri Şekil 9'da gösterilmiştir.

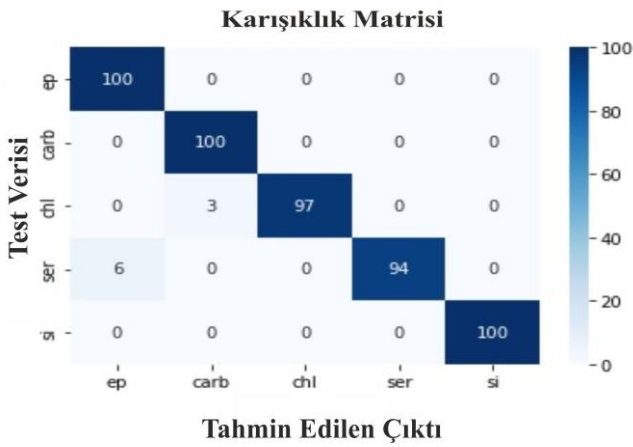


Şekil 9. Xception modelinin Adam optimizasyon fonksiyonu ile eğitilmesi sonucu elde edilen (a) Model Doğruluk (Accuracy) ve (b) Model Kayıp (Loss) grafikleri

Bu grafikler incelendiğinde yüksek doğrulukla bir öğrenme gerçekleştiği ağırlıklı ve doğru bir şekilde öğrenimi tamamladığı ve doğruluk olarak 0.98 değerine ulaştığı görülmektedir. ESA modelinde olduğu gibi Adam optimizasyon fonksiyonunun öğrenme başarısı oldukça yüksektir.

Ağın Adam optimizasyon fonksiyonu ile çalıştırılması sonucu elde edilen karışıklık matrisine göre (Şekil 10); epidotlaşma, karbonatlaşma ve silisleşme sınıfları tamamen doğru sınıflandırılmış, kloritleşme sınıfının 3 tanesi karbonatlaşma sınıfına atanmıştır.

Serizitleşme sınıfın 6 tanesi ise epidotlaşma sınıfına atanmıştır. Toplamda 500 tane test verisinin 491 tanesi doğru sınıfa atanırken 9 tanesi farklı sınıflara atanmıştır.



Şekil 10. Adam optimizasyon fonksiyonu ile eğitilen Xception modeline ait Karışıklık Matrisi

Xception modelinin Adam optimizasyon fonksiyonu ile eğitilmesi sonucunda elde edilen sonuçlar Tablo 5’te gösterilmiştir.


Tablo 5. Adam optimizasyon fonksiyonuna ait sonuçlar

	precision	recall	f1-score	support
epidotlaşma	0.94	1.00	0.97	100
karbonatlaşma	0.97	1.00	0.99	100
kloritlesme	1.00	0.97	0.98	100
serizit	1.00	0.94	0.97	100
silislesme	1.00	1.00	1.00	100
Doğruluk (accu.)			0.98	500
Makro ort.	0.98	0.98	0.98	500
Ağırlıklı ort.	0.98	0.98	0.98	500

Adam optimizasyon fonksiyonu ile eğitilen modelin doğruluğu 0.98 olarak hesaplanmıştır. Bu değer ESA modeli ile karşılaştırıldığında 0.2 puan daha yüksek olsa da her iki model için hesaplama süresi kıyaslandığında ESA modelinin Xception’a göre 2.61 kat daha hızlı bir şekilde eğitimi tamamladığı görülmektedir.

3.2.2 Xception- RMSprop

Xception modeli ile oluşturulan ağın, RMSprop optimizasyon fonksiyonu ile eğitilmesine ait Model Doğruluk (Accuracy) ve Model Kayıp (Loss) Grafikleri Şekil 11’de gösterilmiştir.



Şekil 11. Xception modelinin RMSprop optimizasyon fonksiyonu ile eğitilmesi sonucu elde edilen (a) Model Doğruluk (Accuracy) ve (b) Model Kayıp (Loss) grafikleri

Bu grafikler incelendiğinde modelin yüksek doğrulukla bir öğrenme gerçekleştiği ve doğruluk olarak 0.98 değerine ulaştığı görülmektedir. Xception modelinde ESA modelinden farklı olarak RMSprop optimizasyon fonksiyonunun öğrenme hızı ve ulaştığı doğruluk değeri daha yüksektir.

Xception modelinin RMSprop optimizasyon fonksiyonu ile çalıştırılması sonucu elde edilen karışıklık matrisine göre (Şekil 12); epidotlaşma ve karbonatlaşma sınıfları tamamen doğru sınıflandırılmış, kloritleşme sınıfının 2 tanesi epidotlaşma, 1 tanesi ise silisleşme sınıfına atanmıştır.

Serizitleşme sınıfın 3 tanesi kloritleşme 1 tanesi ise silisleşme sınıfına atanmıştır. Silisleşme sınıfı incelendiğinde sadece 1 tanesinin epidotlaşma olarak hatalı sınıflandırıldığı görülebilir.

Toplamda 500 tane test verisinin 492 tanesi doğru sınıfa atanırken 8 tanesi farklı sınıflara atanmıştır.



Şekil 12. RMSprop optimizasyon fonksiyonu ile eğitilen Xception modeline ait karışıklık matrisi

Xception modelinin RMSprop optimizasyon fonksiyonu ile eğitilmesi sonucunda elde edilen sonuçlar Tablo 6' da gösterilmiştir.

Tablo 6. RMSprop optimizasyon fonksiyonuna ait sonuçlar

	precision	recall	f1-score	support
epidotlaşma	0.97	1.00	0.99	100
karbonatlaşma	1.00	1.00	1.00	100
kloritlesme	0.97	0.97	0.97	100
serizit	1.00	0.96	0.98	100
silislesme	0.98	0.99	0.99	100
Doğruluk (accu.)			0.98	500
Makro ort.	0.98	0.98	0.98	500
Ağırlıklı ort.	0.98	0.98	0.98	500

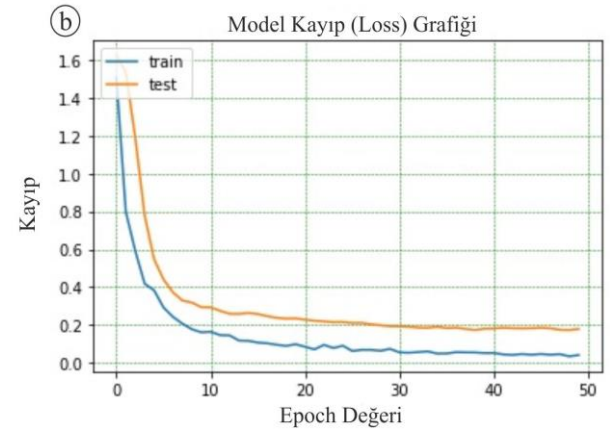
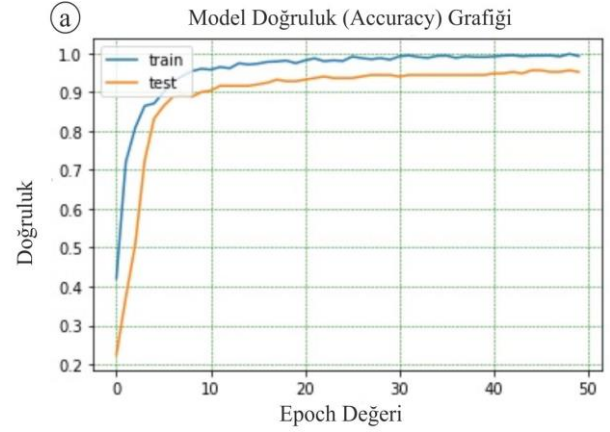
RMSprop optimizasyon fonksiyonu ile eğitilen modelin doğruluğu 0.98 olarak hesaplanmıştır. Xception modelinin Adam fonksiyonu ile hesaplanan değerlere çok yakın sonuçlar elde edilmiştir. Ağın eğitim süresi ESA modeline göre oldukça uzun sürede yaklaşık 2.79 kat daha tamamlanmıştır.

3.2.3 Xception-SGD

Xception modeli ile oluşturulan ağın, SGD optimizasyon fonksiyonu ile eğitilmesine ait Model Doğruluk (Accuracy) ve Model Kayıp (Loss) Grafikleri Şekil 13'te gösterilmiştir.

Bu grafikler incelendiğinde ağın öğreniminin Adam ve RMSprop fonksiyonları ile eğitilen ağlara göre daha yavaş gerçekleştiği test verisinin ancak onuncu epoch değerinden sonra 0.9 doğruluk değerine ulaştığı görülmektedir. Ağın eğitimi tamamlandığında, modelin elde ettiği en yüksek doğruluk değerinin 0.96 olduğu görülmüştür.

SGD optimizasyon fonksiyonu ile eğitilen ESA modeli ile karşılaştırıldığında 0.2 puan daha iyi bir öğrenme değeri elde ettiği hesaplanabilir.



Şekil 13. Xception modelinin SGD optimizasyon fonksiyonu ile eğitilmesi sonucu elde edilen (a) Model Doğruluk (Accuracy) ve (b) Model Kayıp (Loss) grafikleri

Bu grafikler incelendiğinde ağın öğreniminin Adam ve RMSprop fonksiyonları ile eğitilen ağlara göre daha yavaş gerçekleştiği test verisinin ancak onuncu epoch değerinden sonra 0.9 doğruluk değerine ulaştığı görülmektedir. Ağın eğitimi tamamlandığında, modelin elde ettiği en yüksek doğruluk değerinin 0.96 olduğu görülmüştür.

SGD optimizasyon fonksiyonu ile eğitilen ESA modeli ile karşılaştırıldığında 0.2 puan daha iyi bir öğrenme değeri elde ettiği hesaplanabilir.

Xception modelinin SGD optimizasyon fonksiyonu ile çalıştırılması sonucu elde edilen karışıklık matrisine göre (Şekil 14); serizitleşme sınıfı tamamen doğru sınıflandırılmıştır.

Epidotlaşma sınıfının 1 tanesi kloritlesme, 1 tanesi ise silislesme sınıfına atanmıştır. Karbonatlaşma sınıfının 1 tanesi silislesme sınıfına atanmıştır.

Kloritlesme sınıfın 4 tanesi epidotlaşma 1 tanesi ise karbonatlaşma sınıfına atanmıştır. Silislesme sınıfı incelendiğinde 2 tanesinin karbonatlaşma, 2'sinin ise kloritlesme olarak hatalı sınıflandırıldığı görülebilir.

Toplamda 500 tane test verisinin 482 tanesi doğru sınıfa atanırken 18 tanesi ise farklı sınıflara atanmıştır.



Şekil 14. SGD optimizasyon fonksiyonu ile eğitilen Xception modeline ait karışıklık matrisi

Xception modelinin SGD optimizasyon fonksiyonu ile eğitilmesi sonucunda elde edilen sonuçlar Tablo 7’de gösterilmiştir.

Tablo 7. SGD optimizasyon fonksiyonuna ait sonuçlar

	precision	recall	f1-score	support
epidotlasma	0.96	0.98	0.97	100
karbonatlasma	0.97	0.99	0.98	100
kloritleşme	0.97	0.89	0.93	100
serizit	1.00	1.00	1.00	100
silisleşme	0.92	0.96	0.94	100
Doğruluk (accu.)			0.96	500
Makro ort.	0.96	0.96	0.96	500
Ağırlıklı ort.	0.96	0.96	0.96	500

SGD optimizasyon fonksiyonu ile eğitilen modelin doğruluğu 0.96 olarak hesaplanmıştır. Ağın eğitim süresi ESA modeline ile kıyaslandığında yaklaşık 3.45 kat daha uzun sürede tamamlanmıştır.

3.3 ESA ve Xception modellerinin karşılaştırılması

Bu çalışma içerisinde oluşturulan veri seti ile üç farklı optimizasyon fonksiyonu kullanılarak eğitilen ESA ve Xception derin öğrenme modellerine ilişkin simülasyon sonuçlarının karşılaştırılması Tablo 8 içerisinde verilmiştir.

Tablo 8 incelendiğinde, en yüksek başarımların 0.98 değeri ile Xception-Adam ve Xception-RMSprop modellerinin elde ettiği görülmektedir.

Doğru ve yanlış sınıflandırma değerleri referans alındığında Xception-RMSprop modelinin 492 doğru 8 yanlış sınıf eşleştirmesi ile en yüksek orana sahip olduğu Xception-Adam modelinin 491 doğru 9 yanlış sınıf eşleştirmesi ile ikinci sırada yer aldığı görülebilir.

Kayıp (loss) değerleri kıyaslandığında en düşük 0.05 değeri ile Xception-RMSprop modelinin olduğu görülmekte, ikinci sırada ise 0.099 ile ESA-Adam modeli gelmektedir.

Modellere ait eğitim süreleri incelendiğinde ESA modellerinin Xception modellerine göre çok daha hızlı şekilde eğitimi tamamladıkları görülmektedir. ESA-Adam modeli ile Xception-RMSprop modelleri kıyaslandığında ESA-Adam modelinin 2.88 kat daha hızlı işlemi tamladığı hesaplanabilir.

Tablo 8. ESA ve Xception modellerinin kıyaslanması

	Metrik	ESA	Xception
Adam	Doğruluk(acc.)	0.96	0.98
	Kayıp (loss)	0.099	0.14
	Zaman (sn)	128.86	336.88
	Hatalı Sınıf	482	491
	Doğru Sınıf	18	9
RMSprop	Doğruluk(acc.)	0.94	0.98
	Kayıp (loss)	0.17	0.05
	Zaman (sn)	133.13	371.24
	Hatalı Sınıf	471	492
	Doğru Sınıf	29	8
SGD	Doğruluk(acc.)	0.96	0.96
	Kayıp (loss)	0.09	0.18
	Zaman (sn)	132.78	458.93
	Hatalı Sınıf	481	482
	Doğru Sınıf	19	18

4 Sonuçlar

Bu çalışmada, değerli metalik maden yataklarının belirlenmesinde önemli bir rolü olan hidrotermal alterasyon türlerinden olan “epidotlaşma, karbonatlaşma, kloritleşme, serizitleşme, silisleşme” türlerine ait ince kesit görüntülerini barındıran veri seti, Evrişimli Sınır Ağları ile kurulan iki farklı derin öğrenme modeliyle eğitilip test edilmiştir. Bu çalışmada anlatılan ESA modeli en iyi sınıflandırma sonucunu Adam ve SGD optimizasyon fonksiyonu için “0.96” doğruluk oranı ile elde etmiştir. RMSprop optimizasyon fonksiyonu için bu değer 0.94 olarak bulunmuştur. Algoritmaların elde ettikleri en düşük f1 skorları incelendiğinde elde edilen doğruluk, f1 skor ve karışıklık matrisi sonuçları neticesinde, uzmanlar tarafından uzun süreli ve zahmetli süreçlerle belirlenen hidrotermal alterasyon tiplerinin, derin öğrenme ağları kullanılarak %96’ya varan bir doğruluk oranı ile ve bu çalışma kapsamında eğitilen Xception modeline kıyasla oldukça kısa bir sürede tahmin edilebileceğini göstermektedir.

Xception modeli ile eğitilen derin öğrenme ağı ESA modeline kıyasla tüm optimizasyon fonksiyonlarında daha yüksek doğruluk değerine ulaşmıştır. Xception ve ESA modelleri arasındaki doğruluk farkı %2 ile %4’lük bir değer aralığında değişmektedir. Her iki model eğitim süresi olarak kıyaslandığında ise ESA modeli 3.45 kata kadar daha hızlı şekilde ağı eğitimi tamamlamayı başarmıştır.

Bu çalışmada elde edilen veriler, hidrotermal alterasyon tipleri için görüntü tanımlama ve sınıflandırmada derin öğrenmenin başarısını göstermektedir. Bununla birlikte ilerleyen çalışmalarda daha başarılı sınıflandırmalar yapabilmek için veri setinin genişletilerek iki katına

çıkartılması ve VGG, ResNet, GoogLeNet gibi çok daha derin ağların ImageNet gibi büyük bir veri seti ile ön eğitimden geçirildikten sonra transfer öğrenme yöntemi ile eğitilerek kullanılması planlanmaktadır.

Çıkar çatışması

Yazarlar çıkar çatışması olmadığını beyan etmektedir.

Benzerlik oranı (iThenticate): %19

Kaynaklar

- [1] D. G. Tang, K. L. Milliken, ve K. T. Spikes, Machine learning for point counting and segmentation of arenite in thin section, *Mar Pet Geol*, 120, 2020. doi: <https://doi.org/10.1016/j.marpetgeo.2020.104518>.
- [2] M. A. Abdelkader, Y. Watanabe, A. Shebl, H. A. El-Dokouny, M. Dawoud, and Á. Csámer, Effective delineation of rare metal-bearing granites from remote sensing data using machine learning methods: A case study from the Umm Naggat Area, Central Eastern Desert, Egypt, *Ore Geol Rev*, 150, 2022. <https://doi.org/10.1016/j.oregeorev.2022.105184>.
- [3] U. Zidan, H. A. El Desouky, M. M. Gaber, and M. M. Abdelsamea, From pixels to deposits: porphyry mineralization with multispectral convolutional neural networks, *IEEE J Sel Top Appl Earth Obs Remote Sens*, 16, 9474-9486, 2023. <https://doi.org/10.1109/JSTARS.2023.3321714>
- [4] S. Metlek and H. Cetiner, ResUNet+: A new convolutional and attention block-based approach for brain tumor segmentation, *IEEE Access*, 11, 69884–69902, 2023. <https://doi.org/10.1109/ACCESS.2023.3294179>.
- [5] H. Çetiner and S. Metlek, DenseUNet+: A novel hybrid segmentation approach based on multi-modality images for brain tumor segmentation, *Journal of King Saud University-Computer and Information Sciences*, 35(8), 2023. <https://doi.org/10.1016/j.jksuci.2023.101663>.
- [6] F. Pirajno, Hydrothermal Processes and Wall Rock Alteration. 73-164, 2009.
- [7] Ö. Polat, A. Polat, and T. Ekici, Automatic classification of volcanic rocks from thin section images using transfer learning networks, *Neural Comput Appl*, 33(18), 11531–11540, 2021. <https://doi.org/10.1007/s00521-021-05849-3>.
- [8] R. A. Rubo, C. de Carvalho Carneiro, M. F. Michelon, ve R. dos S. Gioria, Digital petrography: Mineralogy and porosity identification using machine learning algorithms in petrographic thin section images, *J Pet Sci Eng*, 183, 2019. <https://doi.org/10.1016/j.petrol.2019.106382>.
- [9] R. P. de Lima ve D. Duarte, Pretraining convolutional neural networks for mudstone petrographic thin-section image classification, *Geosciences (Switzerland)*, 11(8), 2021. <https://doi.org/10.3390/GEOSCIENCES11080336>.
- [10] C. Guojian ve L. Peisong, Rock thin-section image classification based on residual neural network, in 2021 IEEE 6th International Conference on Intelligent Computing and Signal Processing, ICSP 2021, Institute of Electrical and Electronics Engineers Inc., 521–524, 2021. <https://doi.org/10.1109/ICSP51882.2021.9408983>.
- [11] Y. Xu, Z. Dai, ve Y. Luo, Research on application of image enhancement technology in automatic recognition of rock thin section, in IOP Conference Series: Earth and Environmental Science, IOP Publishing Ltd, 2020. <https://doi.org/10.1088/1755-1315/605/1/012024>.
- [12] X. L. Zhang, Z. J. Wang, D. T. Liu, Q. Sun, and J. Wang, Rock thin section image classification based on depth residuals shrinkage network and attention mechanism, *Earth Sci Inform*, 16(2), 1449–1457, 2023. <https://doi.org/10.1007/s12145-023-00981-1>.
- [13] J. C. Á. Iglesias, R. B. M. Santos, and S. Paciornik, Deep learning discrimination of quartz and resin in optical microscopy images of minerals, *Miner Eng*, 138, 79–85, 2019. <https://doi.org/10.1016/j.mineng.2019.04.032>.
- [14] C. L. Bérubé, R. Gema, B. Olivo, C. Chouteau, P. Perrouy, S. Pejman, J. J. Enkin, M.A. William, F. Leonardo, T. Raphaël, Predicting rock type and detecting hydrothermal alteration using machine learning and petrophysical properties of the Canadian Malartic ore and host rocks, Pontiac Subprovince, Québec, Canada, *Ore Geol Rev*, 96, 130–145, 2018. <https://doi.org/10.1016/j.oregeorev.2018.04.011>.
- [15] V. Kúrková, Y. Manolopoulos, B. Hammer, L. Iliadis, ve I. Maglogiannis, Eds., Artificial Neural Networks and Machine Learning – ICANN 2018, 11141, Cham: Springer International Publishing, 2018. <https://doi.org/10.1007/978-3-030-01424-7>.
- [16] Artificial Neural Networks and Machine Learning-ICANN 2018. [Online]. Available: <http://www.springer.com/series/7407>
- [17] S. Kızılok, Fizik Tabanlı Yeni Hibrit Optimizasyon Algoritmalarının Geliştirilmesi ve Veri Madenciliğinde Uygulamaları. Doktora Tezi, Fırat Üniversitesi, Elazığ, Türkiye, 2017.
- [18] M. Beşkirli ve M. F. Tefek, Gradyan Tabanlı Optimize Edici Algoritmasının Parametre Ayarlaması, *European Journal of Science and Technology*, 2021. <https://doi.org/10.31590/ejosat.1010813>.
- [19] M. R. Öner, Derin öğrenme algoritmaları kullanılarak dış ve orta kulak hastalıklarının tespit edilmesi, Konya Teknik Üniversitesi Lisansüstü Eğitim Enstitüsü, 2023.
- [20] Ö. İnik, E. Ülker, Derin öğrenme ve görüntü analizinde kullanılan derin öğrenme modelleri Gaziosmanpaşa Bilimsel Araştırma Dergisi (GBAD), 6 (3), 85- 104, 2017.
- [21] E. Seyyarer F. Ayata, T. Uçkan, A. Karcı, Derin öğrenmede kullanılan optimizasyon algoritmalarının uygulanması ve kıyaslanması, *Anatolian Journal of Computer Sciences*, 5 (2), 90-98, 2020.
- [22] D. P. Kingma ve J. Ba, Adam: A method for stochastic optimization, 2014. [Online]. Available: <http://arxiv.org/abs/1412.6980>

- [23] H. Badem, Parkinson hastalığının ses sinyalleri üzerinden makine öğrenmesi teknikleri ile tanımlanması, Ömer Halisdemir Üniversitesi Mühendislik Bilimleri Dergisi, 2019. <https://doi.org/10.28948/ngumuh.524658>.
- [24] M. Hossin ve M.N. Sulaiman, A Review on Evaluation Metrics for Data Classification Evaluations,

International Journal of Data Mining & Knowledge Management Process, 5 (2), 01–11, 2015. <https://doi.org/10.5121/ijdkp.2015.5201>.

- [25] F. Chollet, Xception: Deep learning with depthwise separable convolutions Proceedings of the IEEE conference on computer vision and pattern recognition. 2017.

