

Yarı-Otomatik Etiketleme Ve Segformer Tabanlı Bölütleme İle QAP Diyagramına Dayalı Kayaç Türü Sınıflandırması

Semi-Automatic Labeling and Segformer-Based Segmentation for Rock Type Classification Based on QAP Diagram

İlhan AYDIN¹, Hüseyin Derviş¹, Taha Kubilay ŞENER¹, Ayşe Didem KILIÇ²

¹Bilgisayar Mühendisliği Bölümü
Fırat Üniversitesi

iaaydin@firat.edu.tr, 231129102@firat.edu.tr, tksener@firat.edu.tr

²Jeoloji Mühendisliği Bölümü
Fırat Üniversitesi
adkilic@firat.edu.tr

Özet

Jeoloji’de kayaç ince kesitlerin tanımlanması, petrojenez, alterasyon, doku, cevherleşme, kayaçlar ve yer kabuğu işlevleri hakkında bilgi almak için kritik öneme sahiptir. Geleneksel ince kesit tanımlama yöntemi uzman deneyimi, kişisel dikkat, ağır iş yükü, uzun tanımlama döngüsü ve doğru nicelleştirme yapılamaması gibi dezavantajlar göstermektedir. Bu çalışma, foid içeren magmatik kayaçların mikroskobik ince kesit görüntülerinden mineral bileşimlerinin otomatik belirlenmesini ve QAP diyagramı üzerinden sınıflandırılmasını amaçlamaktadır. Süperpiksel tabanlı etiketleme aracı kullanılarak veri etiketleme süreci kolaylaştırılmış, ardından Segformer mimarisi ile kuvars, alkali feldispat ve plajiyoklaz mineralleri yüksek doğrulukla bölütlenmiştir. Segmentasyon sonuçları kullanılarak QAP diyagramı üzerinden kayaç türleri otomatik olarak tanımlanmıştır. Karşılaştırmalı deneylerde Segformer modeli, klasik derin öğrenme mimarilerine göre daha yüksek doğruluk (%94.56) ve ortalama IoU (%73.78) başarımları göstermiştir. Bu yaklaşım, jeolojik sınıflandırmalarda otomasyonu artırarak uzman müdahalesine olan ihtiyacı azaltmakta ve daha tutarlı sonuçlar elde edilmesini sağlamaktadır.

Anahtar kelimeler: Kayaç sınıflandırması, semantik bölütleme, QAP diyagramı, süperpiksel etiketleme

Abstract

The identification of geological thin sections is essential for understanding petrogenesis, alteration processes, texture, mineralization, rock types, and the structural evolution of the Earth’s crust. However, traditional thin-section analysis relies heavily on expert interpretation. This analysis is time-consuming, subjective, and often lacks accurate quantitative assessment. This study proposes an automated framework for determining the mineral composition of thin-section images of igneous rocks and classifying them using the QAP diagram. A super-pixel based labeling tool was developed to streamline the annotation process, followed by high-accuracy semantic segmentation of quartz, alkali feldspar, and plagioclase minerals using the SegFormer architecture. Based on the

segmentation outputs, rock types were automatically identified through QAP diagram analysis. Comparative experiments demonstrate that the SegFormer model outperforms conventional deep learning architectures, achieving an accuracy of 94.56% and a mean Intersection over Union (mIoU) of 73.78%. The proposed approach enhances automation in geological classification, reduces dependence on expert intervention, and enables more consistent, objective, and reproducible results.

Keywords: Rock classification, semantic segmentation, QAP diagram, superpixel labeling.

1. Giriş

Magmatik kayaçlar, oluşum yerlerine, mineralojik ve kimyasal bileşimlerine ve renk indislerine göre sınıflandırılırlar. Magmatik kayaçların mineralojik sınıflaması, kuvars, alkali feldispat, plajiyoklaz ve feldispatoid minerallerine göre QAP-diyagramı üzerinde yapılırken, ultramafik mineraller dikkate alınmaz. Streckeisen [1] tarafından, Q (Kuvars-tridimit, kristobalit), A(Alkali feldispatlar-ortoklaz, sanidin, mikroklin), P(Plajiyoklaz), F(Feldispatoidler-lösit, nefelin, sodalit, analsim) ve M (Koyu renkli mineraller-mika, piroksen, olivin, amfibol) olarak sınıflandırılan diyagramdaki ilk dört mineral açık renklidir. Günümüzde, polarize, floresan, spektroskopi yöntemleri, taramalı elektron mikroskop ve katodoluminesans analizleri üzerinde ince kesit çalışmaları yapılmaktadır [2-5]. Geleneksel ince kesit tanımlamaları, görsel incelemeyle manuel olarak mikroskopta yapılır. Deneyimli uzman gerektiren zaman alıcı ve zahmetli bu süreci büyük veri ve yapay zekâ algoritmaları ile kısaltmak mümkündür [6-8]. Makina öğrenmesi ve derin öğrenme algoritmaları, kayaç sınıflamalarında güvenilir ve hızlı bir yöntem olarak kullanılmaktadır [8-10]. Derin öğrenme, görüntü tanıma ve bilgisayarlı görme teknolojilerinin gelişmesi, minerallerin ve kayaçların sınıflanmasını mümkün kılmaktadır [11]. İnce kesit görüntüsü kullanılarak yapılan çalışmalar arasında, Yu ve diğ. [12], Polat ve diğ. [2], Baykan ve Yılmaz [3], Pires de Lima ve Duarte [13] gibi araştırmacılar farklı kayaç türlerinde derin öğrenme yöntemlerini uygulamıştır. Yu ve diğ. [12] süperpiksel algoritmalarının,

makine öğrenmesi uygulamaları için eğitim veri setlerinin oluşturulması bakımından önemli bir adım olarak, sedimanter kayaç ince kesit görüntü veri setlerini kullanmıştır. Araştırmacılar, MultiSLIC'in birden fazla girdi görüntüsü verildiğinde mineral tane sınır uyumu sağlayan kompakt süperpikseller çıkarabildiğini göstermiştir. Test sonuçları, büyük ve karmaşık ince kesit görüntülerinin piksel düzeyinde doğru etiketlerle, geleneksel ve tamamen manuel çalışmalara kıyasla etiketleme aracı kullanılabileceğini belirlemiştir. Polat ve diğ. [2] plütonik kayaç ince kesitlerini kullandığı çalışmada, geleneksel sinir ağları metodunu ile plütonik kayaçlarda kuvars, alkali feldispat ve plajiyoklaz gibi bazı mineralleri belirlemiştir. Bu üç minerali temel aldığı çalışmalarında araştırmacılar, %97.52'lik doğruluğa ulaşmıştır. Baykan ve Yılmaz [3], yapay sinir ağlarını klorit, muskovit, biyotit ve opak mineraller gibi polarizan ışıktaki renkli özelliğe sahip mineraller için uygulamışlardır. Bu çalışmada, mikroskopta çapraz polarize ışıktaki alınan kayaç ince kesit görüntülerinde %89,53'lük doğru sınıflandırma yapılmıştır. Pires de Lima ve Duarte [13] petrografik ince kesit görüntülerinin sınıflandırılması görevine ince ayar yapılarak, ImageNet üzerinde önceden eğitilmiş CNN modellerinin, daha fazla örnek sayısı ve de ImageNet'teki örnek çeşitliliğinin değerlendirmiş ve diğer veri setlerine kıyasla daha yüksek doğruluk verdiğini kanıtlamıştır.

Jeoloji biliminde makine öğrenmesi ve derin öğrenme algoritmalarının kullanılması ile yapılandırılmış veriler [7], jeokimyasal anormallikler [2-5,13], potansiyel mineral kaynakları [14-15] ve paleontolojik verilerin yüksek doğrulukta değerlendirmesi sağlanmıştır. Jeolojide derin öğrenmede yaşanan gelişmelerle, görüntü tabanlı bilgisayarlı görme teknolojisi kullanılarak ince kesit görüntüleri sınıflandırılabilir. Kaya ince kesit görüntülerinin sınıflandırılmasında, U-Net [16], Residual Network (ResNet) [10], Visual Geometry Group (VGG) [17], DenseNet [18], Faster R-CNN [18] ve Inception-v3 [19] gibi evrimsel sinir ağı (CNN) modelleri kullanılmaktadır. Marmo ve diğ. [20], yapay sinir ağları (ANN)'yi karbonat ince kesit görüntülerinde kullanmış ve %93.5' lik bir başarı sağlamıştır. Patel ve diğerleri [21], probabilistik sinir ağlarını (PNN) farklı dokuda kireçtaşlarında dokuz histogram özelliği ile birlikte kullanmıştır. K-en yakın komşu algoritmaları ile dokuz farklı kayaç türünü sınıflandırmıştır. Bir başka çalışmada, Polat ve diğerleri [2] altı volkanik kayaç türünü otomatik sınıflamak için iki CNNs algoritmasını kullanmıştır. Karbonat kayaçların ince kesit görüntülerindeki üç özelliğe dört CNN modelini uygulamıştır. Kayaç ince kesitlerinde CNN ile mineral segmentasyonu kullanmıştır [22]. Bazı araştırmacılar, kayaç ince kesitlerinde kayacın beş farklı özelliğini ResNet0 sinir ağları kullanarak belirlemeye çalışmış ve başarı sağlamıştır [23]. Bazı çalışmalarda, üç kayaç türü (magmatik, metamorfik ve sedimanter) sınıflamasında SeNet' e dayanarak CNN model özelliğini artırarak başarı sağlamış ve dataset üzerinde %90.89 başarı elde etmiştir [24]. Chen ve diğ. [14] ResNet50 ve ResNet 101 sinir ağlarını kayaç ince kesitlerini tanımlamak için kullanmış ve %90.24-%91.63 performans sağlamıştır. Zhang ve diğerleri [16] Inception-V3 derin öğrenme modeli ve transfer derin öğrenme modelini kullanarak, granit, fillit ve breş türü kayaçları sınıflandırmıştır. Su ve diğ. [25], pirit, kalkopirit, galen ve sfalerit ince kesit görüntülerinde UNet modelini kullanmıştır. Veri artırımından sonra bu mineral türlerinde %90 başarı elde edilmiştir. Zhong ve diğ. [26], kumtaşı, oolitik kireçtaşı, litik kumtaşı, granit ve kuvarşlı kumtaşlarında VGG modelini uygulamışlardır. Bu

araştırmacılar veri setlerinde %82' lik başarı yakalamışlardır. Visual Geometry Group ağları (VGG) [26], UNet [27], Yoğun iletişimsel sinir ağları ResNet [28], DenseNet [29], Inception+v3 [30] ve hızlı bölgesel iletişimsel sinir ağları (Faster RCNN) [31] gibi evrimsel sinir ağlarına (CNN) gibi derin öğrenme modelleridir. Bu modeller, bilgisayar görmeye mükemmel performans göstermiştir.

Bu çalışmada mikroskop ile alınan ince kesit kayaç görüntülerinden kayaç türünün belirlenmesi için yeni bir yaklaşım önerilmektedir. Önerilen yaklaşım ile jeoloji uzmanlarının ince kesit kayaç görüntülerini hızlı bir şekilde etiketleyebilmesi için süperpiksel tabanlı bir arayüz geliştirilmiştir. Geliştirilen arayüz sayesinde özellikle etiketleme işleminde parametrelerin ayarlanabildiği hızlı ve hassas etiketleme işlemleri yapılabilecektir. Diğer bir katkı ise etiketlenen veriler üzerinde derin öğrenme tabanlı bölütleme yaklaşımları ile kayaç türünün belirlenmesidir. Bu amaçla UNet, DeepLabv3+ ve segformer gibi modeller eğitilmiştir. Modeller içerisinde en yüksek başarıyı veren segformer ile ince kesit kayaç görüntüsündeki kuvars, alkali feldispat, plajiyoklaz minerallerinin oranı bulunarak Kuvars, Alkali feldispat, Plajiyoklaz feldispat (QAP) diyagramından kayaç türü belirlenmiştir. Önerilen yaklaşım jeologlar ve yer bilimciler için kullanışlı araçlar sunmaktadır.

2. Materyal ve Metod

Mikroskop ile alınan ince kesit kayaç görüntülerinden kayaç türünün belirlenmesi için önerilen yaklaşım üç aşamadan oluşmaktadır. İlk aşama veri setini etiketlemek için süperpiksel tabanlı bir yöntemden oluşmaktadır. Superpixels, renk veya doku gibi benzer özelliklere sahip pikselleri gruplayarak, görüntüyü daha büyük ve anlamlı bölgelere ayırır. Bu, görüntü işleme görevlerinin karmaşıklığını azaltır. Superpixel yöntemleri arasında SLIC (Basit Doğrusal Yinelemeli Kümeleme), verimliliği ve etkinliği ile öne çıkar. İkinci aşamada ise elde edilen maskelenmiş görüntüler ve orijinal görüntüler kullanılarak Segformer yöntemi ile bölütleme işlemi yapılmaktadır. Daha sonra bölütlenmiş görüntüden kayaç türünün belirlenmesi için bir QAP diyagramı kullanılarak minerallerin oranına göre mineral türü belirlenmektedir. Önerilen yöntemin blok şeması Şekil 1'de gösterilmiştir.


Şekil 1'de ilk olarak ince kesit kayaç görüntülerinin hızlı bir şekilde etiketlenmesi için SLIC süperpiksel yaklaşımı kullanılmaktadır. Geliştirilen ara yüz ile belirlenen klasördeki her görüntü tek tek alınarak belirlenen parametrelere göre etiketleme işlemi yapılmaktadır. Daha sonra etiketlenen görüntüler bir klasöre kaydedilmekte ve bir veri kümesi oluşturulmaktadır. Veri seti derin öğrenme tabanlı bölütleme algoritmasına verilerek model eğitilmekte ve bölütlenmiş görüntüler elde edilmektedir. Bölütlenmiş görüntüden QAP diyagramına göre kayaç türü belirlenebilmektedir.

2.1. SLIC Süper piksel Algoritması ile Otomatik Etiketleme

SLIC (Simple Linear Iterative Clustering), (x,y) konumunda bulunan bir pikselin CIE Lab (Commission Internationale de l'Éclairage) uzayındaki değeri ile konum bilgisinin kullanıldığı k-means temelli bir superpixel algoritmasıdır [30]. Bu algoritmanın uygulaması basit olup, tek parametre olarak k-means parametresi süper piksel sayısını belirler. Bilgisayar bilimlerinde, görüntü işleme ve bilgisayarlı görü alanlarında çok yaygın olarak kullanılan CIELAB renk uzayında, renkli görüntü piksel renk uzayı sayısı ve piksellerin x ve y

koordinatları kullanılır. Bu 5B uzayda Oklid mesafesini kullanmak için uzamsal mesafeleri normalleştirmek gereklidir. Bunun sebebi, CIELAB uzayında iki renk arasında mümkün olan maksimum mesafe sınırlıyken, x-y düzlemindeki uzamsal mesafe görüntü boyutuna bağlı olmasıdır. Giriş görüntüsündeki piksel sayısı N olmak üzere

giriş görüntüsünü bölütleyecek süper piksel sayısı K olacak şekilde, her bir k başlangıç küme merkezi aşağıda belirtildiği gibi başlatılır.



Şekil 1: İnce kesit kayaç görüntüsünden kayaç türü belirleme için önerilen yaklaşım.

$$C_i = [l_i \quad a_i \quad b_i \quad x_i \quad y_i] \quad (1)$$

Denklem (1)'deki küme merkezleri için eşit boyutlu süper pikseller üretmek için grid aralığı $SS=\sqrt{N/K}$ ile hesaplanır. Herhangi bir süper pikselin uzamsal kapsamı yaklaşık olarak S^2 (bir süper pikselin yaklaşık alanı) olduğundan, bu küme merkeziyle ilişkilendirilen piksellerin süper pikselin etrafındaki $2S \times 2S$ alanı içinde bulunduğu güvenli bir şekilde varsayılır. Şekil 2'de SLIC süperpiksel algoritmasının sözde kodu verilmiştir.

Algoritma: SLIC Süperpiksel bölütleme
 S adımlar ile düzenli bir ızgara alanda küme merkezleri $C_i = [l_i \quad a_i \quad b_i \quad x_i \quad y_i]$ 'nin başlatılması
 3x3 komşuluğunda en düşük gradyan pozisyona küme merkezlerinin taşınması
 L(i)=-1 // Her i pikseli için -1 etiketi atanır
 d(i)=∞ // Her i pikseli için mesafe atanması
 Repeat
 For her küme merkezi C_i için do
 For C_i civarında $2S \times 2S$ bölgesindeki her i pikseli için
 C_i ile i arasındaki mesafeyi(D) hesapla (Denklem 2)
 If $D < d(i)$ then
 d(i)=D
 L(i)=i
 Endif
 Endfor
 Endfor
 Yeni küme merkezlerini hesapla
 Artık hata E'yi hesapla
 Until $E \leq \text{threshold}$

Şekil 2: SLIC algoritması

Şekil 2'deki SLIC algoritmasında 5 boyutlu öklid uzayında bir mesafe tanımlanması yapılması durumunda, farklı süper piksel boyutları için küme davranışlarında tutarsızlık olur. Büyük süper pikseller için, uzamsal mesafeler renk yakınlığından ağır basar ve uzamsal yakınlığa renkten daha fazla önem verir. Bu, görüntü sınırlarına iyi uymayan kompakt süper pikseller üretir. İki mesafeyi tek bir ölçümde birleştirmek için, renk

yakınlığını(N_c) ve uzamsal yakınlığını(N_s) bir küme içindeki ilgili maksimum mesafelerine göre normalleştirmek gerekir. Buna göre D' mesafesi aşağıdaki gibi hesaplanır.

$$d_c = \sqrt{(l_j - l_i)^2 + (a_j - a_i)^2 + (b_j - b_i)^2} \quad (2)$$

$$d_s = \sqrt{(x_j - x_i)^2 + (y_j - y_i)^2} \quad (3)$$

$$D' = \sqrt{\left(\frac{d_c}{N_c}\right)^2 + \left(\frac{d_s}{N_s}\right)^2} \quad (4)$$

Denklem(4)'te belirli bir küme içinde beklenen maksimum uzamsal mesafe (N_s), örnekleme aralığı S ile eşdeğer alınabilir. Fakat maksimum renk mesafesini belirlemek daha zordur. Maksimum renk mesafesindeki değişimi düşürmek için bir M sabit ile bölünebilir. Pratikte D mesafesi aşağıdaki gibi hesaplanır.


$$D = \sqrt{\left(\frac{D_c}{M}\right)^2 + \left(\frac{D_s}{S}\right)^2} \quad (5)$$

Superpixel algoritma yöntemi, daha hızlı ve gerçek zamanlı uygulamalar için uygun olması sayesinde verimli bir özellik sunar. Ayrıca, kompaktlığı sayesinde, nesne sınırlarına oldukça uyumlu superpixels üretebilir. Bu özellik, yüksek kalitede bölütleme sağlar. Boyut ve sayı kontrolü gibi istenilen superpixels sayısının belirlenebilir olması ve bölütleme görevlerinde esneklik sağlar ve karmaşık görüntüler üzerinde kullanım kolaylığı getirir [16]. Bu çalışmada, süper piksel algoritması ile ince kesit görüntülerindeki farklı renklere sahip mineral sınırlarının tespiti için semantik bölütleme kullanılmıştır.

2.2. Segformer Tabanlı Görüntü Bölütleme


İnce kesit kayaç görüntülerinden kayaç türünün belirlenmesi için segfomer yöntemi ile bölütleme sağlanarak kayaçtaki Quvars, Alkali feldispat, Plajiyoklaz feldispat oranları hesaplanacaktır. Segformer transformer tabanlı anlamsal bölütleme sağlayan bir derin öğrenme modelidir. Fakat bu model Görsel dönüştürücüler gibi konumsal kodlamalara bağlı

olmadığından farklı çözünürlüklerdeki görüntüler üzerinde daha iyi sonuç verir. Bu modeldeki temel amaç düşük ağırlıklı bir yapıda kod çözücü ile basit ve verimli bir semantik bölütleme sağlamaktır. Temel özellikleri olarak konumsal kodlama kullanmama, piramit görüntü dönüştürücüleri ile verimli bir öz dikkat mekanizması kullanma ve hafif kod çözücü olarak verilebilir. Şekil 3'te Segformer mimarisi verilmiştir.



Şekil 3: Segformer tabanlı semantik bölütleme mimarisi

Şekil 3'te Segformer'in kullandığı dönüştürücüler verimli bir öz dikkat mekanizması kullanmaktadır. Görsel dönüştürücülerde kullanılan matris çarpımındaki $O(n^2)$ olan hesaplama karmaşıklığı R kat azaltılır. Şekil 4'te kullanılan verimli öz dikkat mekanizması verilmiştir.



Şekil 4: Verimli öz dikkat mekanizması

Şekil 4'te verilen uzamsal azaltma sayesinde K ve V değerleri bir R indirgeme oranı ile düşürülerek model karmaşıklığı azaltılmaktadır. X girişi üzerinde adımli bir evrişim uygulanır. Denklem (1)'de bu durum verilmiştir.

$$X' = Conv_s(X) \in \mathbb{R}^{N' \times C} \quad (1)$$

Denklem (1)'de $N' = \frac{H.W}{R^2}$ ile verilmektedir. Elde edilen yeni X' değeri K ve V'nin hesaplanmasında kullanılacaktır. Aşağıda bu değerlerin hesaplanması verilmiştir.

$$Q = XW_Q \in \mathbb{R}^{N \times C} \quad (2)$$

$$K = X'W_K \in \mathbb{R}^{N' \times C} \quad (3)$$

$$V = X'W_V \in \mathbb{R}^{N' \times C} \quad (4)$$

Denklemlerden elde edilen değerlere göre yeni verimli öz dikkat mekanizması aşağıdaki gibi hesaplanır.

$$Dikkat(Q, K, V) = softmax(\frac{QK^T}{\sqrt{d}})V \quad (5)$$


Denklem (5)'teki dikkat mekanizması hesaplama maliyetini $O(N^2)$ 'den $O(N.N')$ 2ye düşürmektedir. Modelde kullanılan Mix-FNN ise iki doğrusal katmanı koruyarak 3x3 boyutlu bir derin evrişimden geçirir. Denklem (6)'da X girişi için bu yapı verilmiştir.

$$MixFNN(X) = W_2(GELU(DWConv(W_1X))) \quad (6)$$

Denklem (6)'da W_1 ve W_2 doğrusal izdüşümleri göstermektedir. DWConv 3x3 boyutunda derinliksel evrişimi gösterir. En son aşamada ise bir çok katmanlı algılayıcı tabanlı bir kod çözücüden geçirilerek çıktı üretilmektedir. İnce kesit kayaç görüntüleri ve etiketlenmiş arka plan görüntüleri Segformer tabanlı modele verilerek modelin eğitimi yapılmaktadır. Ayrıca farklı modellerin aynı görüntüler üzerinde performans değerlendirmesini yapmak için DeepLabV3+ ve Unet modeli de kullanılmıştır.

2.3. Kayaç Tanımlaması


Magmatik kayaçların petrografik sınıflandırmasında özellikle plütonik kayaçlar için daha AQAP diyagramı oldukça kullanılan bir yöntemdir. Bu araç üçgensel bir sınıflandırma aracı olup kayacın hangi türe denk geldiğini hesaplamak için kullanılır. Diyagramı hesaplamak için kayacın içerdiği Kuvars (Q), Alkali feldispat (A) ve Plajiyoklaz feldispat (P) mineralleri kullanılır. Burada özellikle Alkali feldispat kayacın potasyum açısından zenginliğini ifade eder. Eğer plajiyoklaz feldispat yüksek olursa sodyum-kalsiyum içeren bir feldispat kayaç olduğu belirlenir. Şekil 5'te QAP diyagramı verilmiştir.



Şekil 5: QAP diyagramı[1].

Şekil 5'teki QAP diyagramında bu üç bileşenin toplamı %100 olacak şekilde normalize edilir ve her kayaç bileşeni diyagramda bir nokta olarak temsil edilir. Böylece mineralojik içeriğe göre belirli alanlara düşürülmesi sağlanır. Eğer yüksek kuvars var ise A ve P oranları dengede olup granit bir kayaç olduğu ifade edilir. Eğer Plajiyoklaz oranı yüksek ise kayacın tonalit olduğu ifade edilir. Kuvars oranı çok düşük olan feldispatça zengin kayaçlar ise syenit ve monzonit olarak ifade edilir. Kayaç oranı %90'dan fazla olan kayaçlar ise monomineralik kayaçlar olup Quartzolite olarak adlandırılır. QAP diyagramı, IUGS (International Union of Geological

Sciences) tarafından önerilen standart sınıflandırma sistemlerine dayanır ve özellikle ince kesit analizleri ile yapılan nokta sayımı (modal analiz) sonuçlarının değerlendirilmesinde kullanılır. Bu yöntem sayesinde farklı magmatik kayaç türleri arasında kesin ve tutarlı bir sınıflandırma yapılabilir. Bu çalışmada QAP diyagramını oluşturmak ve kayaç türünü otomatik belirlemek için bir yaklaşım önerilmiştir. İlk olarak bölütlenmiş görüntüden elde edilen Q, A ve P değerleri normalize edilmektedir. Daha sonra Şekil 6'daki algoritma ile kayaç türü belirlenmektedir.



Şekil 6: Bölütlenmiş görüntüden kayaç türü belirleme yaklaşımı

Şekil 6'da verilen algoritma ile bölütlenmiş görüntüden kayaç türü belirlenmekte ve daha sonra kayacın türü QAP diyagramında da gösterilmektedir.

2.4. Değerlendirme metrikleri

Bu çalışmada, ince kesit kayaç görüntüleri üzerinde kuvars, alkali feldispat ve plajiyoklaz feldispat minerallerini piksel düzeyinde ayırt etmek amacıyla semantik bölütleme gerçekleştirilmiştir. Bu minerallerin mikroskobik yapılarındaki görsel benzerlikler ve sınır belirsizlikleri, bölütleme problemini oldukça karmaşık hale getirmektedir. Bu nedenle, model performansını değerlendirmek için hem genel doğruluk hem de sınıf bazlı benzerlik ölçütü olan Ortalama Intersection over Union (mIoU) metrikleri kullanılmıştır. Doğruluk, modelin tüm piksel tahminleri içerisinde kaç tanesinin doğru sınıflandırıldığını gösterir. Ancak, sınıflar arasında dengesizlik mevcutsa (örneğin, kuvars çok daha baskınsa), bu metrik yanıltıcı olabilir. Doğruluk, doğru tahmin edilen piksel sayısının toplam piksel sayısına oranı olarak tanımlanmakta olup Denklem (7)'de gösterildiği gibi hesaplanmaktadır.

$$\text{Doğruluk} = \frac{\text{Doğru tahmin edilen piksel sayısı}}{\text{Toplam piksel sayısı}} \quad (7)$$

Intersection over Union (IoU), tahmin edilen segmentler ile gerçek segmentler arasındaki örtüşme oranını ölçen bir metriktir. Bu ölçüt her bir sınıf için ayrı ayrı hesaplanabilmekte olup tahmin edilen (P) ve gerçek (G) segmentlerin kesişiminin birleşimlerine oranı olarak Denklem (8)'de ifade edildiği şekilde tanımlanmaktadır.

$$\text{IoU} = \frac{|P \cap G|}{|P \cup G|} \quad (8)$$

Mean Intersection over Union (mIoU) ise IoU değerlerinin tüm sınıflar üzerindeki ortalamasını temsil etmekte ve bölütleme modelinin sınıflar arasındaki genel performansını dengeleyerek değerlendirmektedir. mIoU, her sınıf için hesaplanan doğru pozitif (TP), yanlış pozitif (FP) ve yanlış negatif (FN) değerleri kullanılarak Denklem (9)'da verilen formül ile hesaplanmaktadır.


$$\text{mIoU} = \frac{1}{N} \sum_{i=1}^N \frac{TP_i}{TP_i + FP_i + FN_i} \quad (9)$$

Burada N sınıf sayısını, TP_i, FP_i ve FN_i ise sırasıyla i. sınıfa ait doğru pozitif, yanlış pozitif ve yanlış negatif piksel sayılarını ifade etmektedir.

3. Deneysel Sonuçlar


Veri seti için Fırat Üniversitesi jeoloji mühendisliği laboratuvarında hazırlanan kayaç ince kesitler kullanılmıştır. Herhangi bir kayıplı sıkıştırma formatı kullanılmamıştır. Veriler, PNG formatında tutulmuş olup polarizan araştırma mikroskobunda (Nikon marka) çapraz polarize ışık (XPL) ve tek polarize ışık (PPL) kullanılarak ince kesit görüntüleri fotoğraflanmıştır.

Feldispatlar, magmatik kayaçların ana bileşimini oluştururken (>%50), feldispatoidli kayaçlar sınırlıdır. Feldispatoidler, silis içermeyen eriyiklerden itibaren oluşur ve feldispatların yerini, lösit (KAlSi₃O₆) ve nefelin (NaAlSi₃O₄) gibi feldispatoid mineralleri alır. Sodalit, lazurit, hauyn, nosean ve petalit ise diğer feldispatoid kayaçlarıdır. Feldispatoid minerallerden birini veya birkaçını birarada bulunduran kayaca ise foid- denir (Foid-monzonit gibi). Foid- veya fonolit kayaçlarında feldispatoidler, ya alkali feldispatla veya plajiyoklazla (anortit) birlikte bulunabilir. Hazırlanan veri seti 2927 eğitim ve 737 doğrulama olmak üzere toplam 3644 görüntüden oluşmaktadır. Verileri etiketlemek için SLIC süperpiksel algoritmasını kullanan bir arayüz hazırlanmıştır. SLIC algoritması, scikit-image kütüphanesindeki skimage-segmentation-slic fonksiyonu kullanılarak uygulanmıştır. Algoritma, GUI'nin hesaplama sırasında duyarlı kalmasını için ayrı bir iş parçasığında çalıştırılır. Şekil 7'de SLIC ile etiketleme için kullanılan arayüz verilmiştir.



Şekil 7: GUI tabanlı etiketleme aracının ekran görüntüsü.

GUI, sol panel ve sağ panel olarak ikiye ayrılır. Görüntüleri yükleme, SLIC parametrelerini ayarlama ve etiketleme için sınıf seçme kontrolleri sol panelde, orijinal görüntüyü ve karşılık gelen bölütlemeye maskesi ise sağ panelde yer alır. GUI'nin temel öğeleri; Görüntü listesi, SLIC parametre kontrolleri, Sınıf seçme açılır menüsü, Yakınlaştırma kaydırıcısı ve Maske görünümü geçişidir. Görüntü Listesi, yüklenen görüntülerin listesini gösterir ve kullanıcılar arasında geçiş yapmayı sağlarken, her bir görüntüde dosya adı ve dosya boyutu yer alır. Bu özellik, istenilen herhangi bir görüntünün kolayca bulunmasına imkân verir. SLIC Parametre Kontrolleri, süperpixel sayısını ($n_segments$) ve kompaktlığı ayarlamak için kaydırıcı olup, kullanıcıların süperpixel oluşturma sürecini ihtiyaçlarına göre hassas bir şekilde ayarlar. Sınıf Seçme Açılır Menüsü, etiketleme için sınıf seçmeyi sağlarken, araç, birden fazla sınıfı destekler. Kullanıcılar gerektiğinde sınıf ekleyebilir, düzenleyebilir veya silebilir. Yakınlaştırma Kaydırıcısı, kullanıcıların görüntüyü yakınlaştırmasını ve uzaklaştırmasını sağlayan bu bölüm, yüksek çözünürlükte görüntüler veya küçük nesneler için oldukça avantajlıdır. Son olarak, Maske Görünümü Geçişi, kullanıcıların bölütlemeye maskesinin görünür veya gizli olmasını sağlar. Dolayısıyla, kullanıcıların orijinal görüntüyü etiketlenmiş maske ile karşılaştırmasına olanak tanıırken doğru etiketleme yapılması mümkün olur. Şekil 8'de veri setinden bazı orijinal görüntüler ve etiketlenmiş veriler verilmiştir.



Şekil 8: Veri setinden dört örnek ve etiketlenmiş örnekleri


Etiketleme işleminden sonra bölütlemeye işlemi yapılacaktır. Bu amaçla hem klasik evrişimsel sinir ağı tabanlı DeeplabV3+ ile Unet modeli kullanılmış hem de dönüştürücü tabanlı Segformer modeli kullanılmıştır. Eğitim için kullanılan parametreler Tablo 1'de verilmiştir.

Tablo 1: Bölütlemeye modelleri için eğitim parametreleri


Parametre	Değer
Veri boyutu	512x512
Sınıf sayısı	4
Parti boyutu	4
Öğrenme oranı	6e-5
Ağırlık düşürme	0.01
Optimizasyon algoritması	AdamW
Adım sayısı	50

Her bir model bu metriklere göre eğitilerek eğitim ve doğrulama için model grafikleri elde edilmiştir. Şekil 9'da


eğitim ve doğrulama için doğruluk ve MIoU grafikleri verilmiştir.



(a) U-Net



(b) DeepLabV3+



(c) Segformer

Şekil 9: Farklı modeller için eğitim grafikleri

Şekil 9'da elde edilen eğitim grafikleri Segformer'in hem eğitim hem de doğrulama için diğer iki modelden daha başarılı sonuçlar elde ettiğini göstermektedir. Her üç model için elde edilen sonuçlar Tablo 2'de verilmiştir.


Tablo 2: Üç model için eğitim ve doğrulama aşamalarındaki metrikler

Metrik	Aşama	Unet	DeepLabV3+	Segformer
Doğruluk	Eğitim	94.83	95.90	97.00
MIoU	Eğitim	80.00	86.39	87.08
Doğruluk	Doğrulama	88.10	90.45	94.56
MIoU	Doğrulama	64.06	66.93	73.78

Tablo 2'de Segformer'in bütün metriklerde diğer iki modele göre daha iyi sonuç verdiği görülmektedir. Ayrıca önerilen modellerin bölütlemeye sonuçları Şekil 10'da gösterilmiştir. Şekil 10'un Görüntü tarafında, gerçek kayaç ince kesitlerinden elde edilmiş bir mikroskop görüntüsü bulunur. Bu görüntüde

magmatik kayaç örneğinden hazırlanan kayaç ince kesitinde plajiyoklas, alkali feldispat ve kuvars mineralleri yaygındır. Görüntüde izleneceği gibi her mineralin kendine özgü bir renk ve morfolojik yapısı vardır. Bu mineralleri seçebilmek için eğitilen modeller, mineral tespiti bakımından ve model başarısı açısından kritik öneme sahiptir. Çalışmada kullanılan SegFormer modeli, DeepLabV3+ ve U-Net modellerine kıyasla daha yüksek doğruluk değerleri elde etmiş olup, bölütleme


sonuçları bakımından Ground truth ile neredeyse aynı düzeyde bir performans sergilemiştir. Ancak SegFormer daha başarılıdır. Özellikle küçük parçaların bölütlenmesi açısından Segformer modeli DeepLabV3+ ve U-net'e kıyasla şekil 10 üzerinde bulunan 1. ve 4. Örnek resimlerde net olarak gösterilmiştir.



Şekil 10: Farklı görüntüler üzerinde UNet, DeepLabV3+ ve Segformer modelinin bölütleme sonuçları

Şekil 10'da verilen bölütleme sonuçları, UNet, DeepLabV3+ ve Segformer modellerinin mineral sınıflandırma başarısını karşılaştırmalı olarak görselleştirmektedir. Görseller incelendiğinde, Segformer modelinin hem sınıf ayrımı hem de alan bütünlüğü açısından en tutarlı sonuçları verdiği görülmektedir. Özellikle kuvars, plajiyoklas ve alkali feldspat gibi minerallerin sınırlarını net bir şekilde ayırt edebilmesi ile bu modelin ince detaylardaki başarısı görülmektedir. UNet modeli belirli örneklerde başarılı olsa da sınırlarda bulanıklık

ve detay kaybı yaşarken, DeepLabV3+ modelinde bazı sınıfların fazla genelleştirildiği ve sınırların bozulduğu gözlemlenmiştir. Genel olarak, Segformer modeli, ince kesit görüntülerinde daha doğru ve dengeli segmentasyon performansı sergilemiştir. Şekil 11'de, Segformer modeli ile elde edilen segmentasyon maskelerine karşılık gelen QAP diyagramları kullanılarak kayaç tipi sınıflandırması gerçekleştirilmiştir.



Şekil 11: Segformer ile bölütleme sonucu elde edilen görüntüden QAP diyagramından kayaç tipi belirleme

Şekil 11’de her bir örnekte, tahmin maskesi üzerinde kuvars (mavi), plajiyoklaz (yeşil) ve alkali feldspat (kırmızı) oranları hesaplanarak QAP üçgeninde gösterilmiştir. İlk örnekte yoğun plajiyoklaz içeriği nedeniyle örnek Tonalite olarak sınıflandırılmıştır. İkinci örnekte yüksek kuvars oranı ve dengeli A/P dağılımı ile Granodiorit, üçüncü örnekte ise kuvars oranı düşük, alkali feldspat oranı baskın olduğundan Monzonit olarak belirlenmiştir. Bu analiz, segmentasyon sonucunun sadece görsel değil, aynı zamanda jeopetrografik yorumlara da olanak sağlayacak düzeyde nitelikli olduğunu göstermektedir.

4. Sonuçlar

Bu çalışmada, ince kesit kayaç görüntülerinden kuvars, alkali feldspat ve plajiyoklaz minerallerinin semantik bölütlemesi gerçekleştirilerek QAP diyagramı aracılığıyla otomatik kayaç türü tespiti yapılmıştır. Karşılaştırmalı deneysel sonuçlar, transformer tabanlı Segformer mimarisinin, klasik evrimsel sinir ağı tabanlı DeepLabV3+ ve UNet modellerine kıyasla doğruluk ve mIoU metriklerinde üstün performans gösterdiğini ortaya koymuştur. Segmentasyon başarımının yüksek olması, özellikle mikroskobik mineral sınırlarının doğru şekilde ayrıştırılması açısından kritik önem taşımaktadır. Ayrıca, elde edilen segmentasyon maskelerinin QAP diyagramı ile entegre

[kullanımı, sadece sınıflandırma değil, aynı zamanda jeopetrografik analiz açısından da değerli ve güvenilir bir çıkarım sağlamıştır. Bu bağlamda, önerilen yöntem, hem etiketleme sürecindeki verimlilik hem de bölütleme ve sınıflandırmadaki doğruluk açısından literatüre önemli bir katkı sunmaktadır.

Teşekkür

Bu makale TÜBİTAK tarafından 123E368 numaralı projeye desteklenmiştir. Desteklerinden dolayı TÜBİTAK kurumuna teşekkür ederiz.

5. Kaynaklar

- [1] A. Streckeisen, "Classification and nomenclature of plutonic rocks: recommendations of the IUGS subcommission on the systematics of igneous rocks.", *Geologische Rundschau*, 63, 773–786, 1974.
- [2] Ö. Polat, A. Polat, T. Ekici, "Automatic classification of volcanic rocks from thin section images using transfer learning networks.", *Neural Computing and Applications*, 33(18), 11531–11540, 2021.

- [3] N.A. Baykan, N. Yılmaz, "Mineral identification using color spaces and artificial neural networks.", *Computers & Geosciences*, 36, 91–97, 2010.
- [4] E. Menteşe, E. Hançer, "Histopatoloji Görüntülerde Derin Öğrenme Yöntemleri ile Çekirdek Segmentasyonu.", *Avrupa Bilim ve Teknoloji Dergisi*, (Özel Sayı), 95-102, 2020.
- [5] S. Aligholi, G.R. Lashkaripour, R. Khajavi, M. Razmara, "Automatic mineral identification using color tracking.", *Pattern Recogn.*, 65, 164–174, 2017.
- [6] A. Balasubramanian, "Branches of Geology(Earth Sciences)", Department of Studies in Earth Science Centre for Advanced Studies University of Mysore, 570-006, , 2017.
- [7] W. Lai, Ji. Jiang, J. Qiu, J. Yu, X. Hu, "Photomicrograph dataset of rocks for petrology teaching in Nanjing University[DS/OL]", *Science Data Bank*, V1, 2020.
- [8] D. Li, J. Zhao, J. Ma, "Experimental studies on rock thin-section image classification by deep learning-based approaches.", *Mathematics*, 10(13), 2317, 2022.
- [9] B. Cheng, I. Misra, A. G. Schwing, A. Kirillov, R. Girdhar, "Masked-attention mask transformer for universal image segmentation.", *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*, 1290-1299, 2022.
- [10] L.C. Chen, G. Papandreou, F. Schroff, H. Adam, "Rethinking atrous convolution for semantic image segmentation.", *arXiv*, , arXiv:1706.05587, 2017.
- [11] C. Sun, A. Shrivastava, S. Singh, A. Gupta, "Revisiting unreasonable effectiveness of data in deep learning era.", In: *ICCV*, 2017.
- [12] J. Yu, F. Wellmann, S. Virgo, M. von Domarus, M. Jiang, J. Schmatz, B. Leibe, "Superpixel segmentations for thin sections: Evaluation of methods to enable the generation of machine learning training data sets.", *Computers & Geosciences*, 170, 105232, 2023.
- [13] R. Pires de Lima, D. Duarte, "Pretraining convolutional neural networks for mudstone petrographic thin-section image classification.", *Geosciences*, 11(8), 336, 2021.
- [14] L. Chen, Y. Zhu, G. Papandreou, F. Schroff, H. Adam, "Encoder-Decoder with Atrous Separable Convolution for Semantic Image Segmentation", *CoRR*, , abs/1802.02611, 2018.
- [15] R. P. de Lima, D. Duarte, C. Nicholson, R. Slatt, K. J. Marfurt, "Petrographic microfacies classification with deep convolutional neural networks.", *Computers & Geosciences*, 142, 104481, 2020.
- [16] P. Zhang, J. Zhou, W. Zhao, X. Li, L. Pu, "The edge segmentation of grains in thin-section petrographic images utilising extinction consistency perception network.", *Complex & Intelligent Systems*, 10(1), 1231-1245, 2024.
- [17] W. Seo, Y. Kim, H. Sim, Y. Song, T. S. Yun, "Classification of igneous rocks from petrographic thin section images using convolutional neural network.", *Earth Science Informatics*, 15(2), 1297-1307, 2022.
- [18] H. Liu, Y. L. Ren, X. Li, Y. X. Hu, J. P. Wu, B. Li, L. Luo, Z. Tao, X. Liu, J. Liang, Y. Y. Zhang, X. Y. An, W. K. Fang, "Rock thin-section analysis and identification based on artificial intelligent technique.", *Petroleum Science*, 19(4), 1605-1621, 2022.
- [19] E. Xie, W. Wang, Z. Yu, A. Anandkumar, J. Alvarez, P. Luo, "SegFormer: Simple and efficient design for semantic segmentation with transformers.", *Advances in Neural Information Processing Systems*, 34, 12077-12090, 2021.
- [20] R. Marmo, S. Amodio, R. Tagliaferri, V. S. Ferreri, G. Longo, "Textural identification of carbonate rocks by image processing and neural network: methodology proposal and examples", *Computers & Geosciences*, 31(5), 649-659, 2005.
- [21] A. Patel, S. Chatterjee, "Computer vision-based limestone rock-type classification using probabilistic neural network.", *Geoscience Frontiers*, 7(1), 53-60, 2016.
- [22] F. Fueten, J. Mason, "An artificial neural net assisted approach to editing edges in petrographic images collected with the rotating polarizer stage.", *Computers & Geosciences*, 33(9), 1176-1188, 2007.
- [23] J.S. Goodchild, F. Fueten, "Edge detection in petrographic images using the rotating polarizer stage.", *Computers & Geosciences*, 24, 745-751, 1998.
- [24] P. Gottlieb, G. Wilkie, D. Sutherland, E. Ho-Tun, S. Suthers, K. Perera, J. Rayner, "Using quantitative electron microscopy for process mineralogy applications.", *JOM*, 52(4), 24-25, 2000.
- [25] C. Su, S. J. Xu, K. Y. Zhu, X. C. Zhang, "Rock classification in petrographic thin section images based on concatenated convolutional neural networks.", *arXiv*:2003.10437, 2020.
- [26] Zhong J, Meng Y, Liu Z. "Multichannel Sandstone Thin Sections Identification Based on Improved DeepLab V3 Plus Neural Network". *ACS Omega*. 2024 Jun 17, 9(26), 28611-28625.
- [27] S. Karimpouli, P. Tahmasebi, "Segmentation of digital rock images using deep convolutional autoencoder networks.", *Computers & Geosciences*, 126, 142-150, 2019.
- [28] I. Kononenko, E. Simec, M. Robnik-Šikonja, "Overcoming the myopia of inductive learning algorithms with RELIEFF.", *Applied Intelligence*, 7, 39-55, 1997.
- [29] N. Li, H. Hao, Q. Gu, D. Wang, X. Hu, "A transfer learning method for automatic identification of sandstone microscopic images.", *Computers & Geosciences*, 103, 111–121, 2017.
- [30] H. Ma, G. Han, L. Peng, L. Zhu, J. Shu, "Rock thin sections identification based on improved squeeze-and-excitation networks model.", *Computers & Geosciences*, 152, 104780, 2021.
- [31] H. Wang, W. Cao, Y. Zhou, P. Yu, W. Yang, "Multitarget Intelligent Recognition of Petrographic Thin Section Images Based on Faster RCNN". *Minerals*, 2023, 13, 872. <https://doi.org/10.3390/min13070872>

Özgeçmiş



İlhan Aydın, 1981 yılında Elazığ'da doğdu. Lisans ve Yüksek Lisans derecelerini Fırat Üniversitesi Bilgisayar Mühendisliğinde 2001 ve 2006 yıllarında aldı. Doktora derecesini 2011 yılında Fırat Üniversitesi, Elazığ Elektrik ve Elektronik Mühendisliği bölümünden aldı. Halen Fırat Üniversitesi'nde Bilgisayar Mühendisliği bölümünde Profesör olarak görev yapmaktadır.

Özgeçmiş



Hüseyin Derviş, 1999 Suriye/Humus doğumludur. Lise öğrenimini 2019 yılında Açık Öğretim Lisesi'nde tamamlamıştır. 2023 yılında Bilgisayar Mühendisliği bölümünden mezun olan Derviş, aynı yıl başladığı lisansüstü eğitimine halen devam etmektedir. Çalışma alanları; yapay zeka, görüntü işleme ve derin öğrenme teknolojileri üzerine yoğunlaşmaktadır.

Özgeçmiş



Taha Kubilay Şener, 1999 Elazığ doğumludur. İlk, orta ve lise öğrenimini Elazığ'da tamamladı. 2018 yılında başladığı Fırat Üniversitesi Bilgisayar Mühendisliğini 2022 yılında tamamladı. Fırat Üniversitesi Bilgisayar Mühendisliğinde Lisansüstü eğitime devam etmektedir. Çalışma alanları yapay zeka, görüntü işleme ve derin öğrenme alanlarındadır.

Özgeçmiş



Ayşe Didem KILIÇ, 1973 Elazığ doğumlu. Lisans eğitimini Fırat Üniversitesi Jeoloji Mühendisliği bölümünde tamamladı. Yüksek Lisansını Pamukkale Üniversitesi Jeoloji Mühendisliği'nde Doktora eğitimini Fırat Üniversitesi Jeoloji Mühendisliği bölümü'nde tamamladı. Halen Fırat Üniversitesi'nde Jeoloji Mühendisliği bölümünde Doçent olarak görev yapmaktadır.