

YAPAY SİNİR AĞLARI KULLANILARAK KARBONAT KAYALARINDAKİ DOKUNUN TANIMLANMASINA BİR ÖRNEK: AKVEREN FORMASYONU

A Case Study for Identification of Texture in Carbonate Rocks Using Artificial Neural Networks: Akveren Formation

Şerafeddin ÇAKIR¹, H. Metin ERTUNÇ² ve Hasan OCAK²

ÖZET

Mikroskopta incelenen karbonat kayalarda dokunun türünün belirlenmesi jeolojik araştırmalarda önemlidir. Petrol sondajlarında olduğu gibi kayaç örneklerinin hızlı bir şekilde değerlendirilmesi gereken durumlarda bu örneklerin tanımlanması görüntü işleme teknikleri ve yapay sinir ağları kullanılarak hızlı bir şekilde yapılabilir. Daha önceki bir çalışmada, bu yöntem kullanıldığı zaman kireçtaşı örneğinin, Dunham (1962) sınıflamasında çamurtaşı, vaketaşı, istiftaşı, tanetaşı olarak sınıflanan örneklerin yapay sinir ağları kullanılarak % 93 oranında dokunun doğru olarak belirlenebileceği yayınlanmıştır. Bu çalışma ise daha önce denenmiş yukarıdaki yöntemin İzmit ve çevresindeki Akveren formasyonu kayaç örneklerine uygulanmasıdır. Akveren formasyonundan alınan kayaç örneklerinden 45 adet ince kesit yapılmıştır. Bu ince kesitlerin fotoğrafları çekilerek bu görüntüler bilgisayarda MATLAB programında "Sobel" filtresi kullanılarak görüntü işleme çalışması ve sonra yapay sinir ağları kullanılarak yukarıdaki 4 sınıftan hangisine yerleşeceği konusu irdelenmiş ve mikroskopta belirlenen doku sınıflamasıyla karşılaştırılmıştır.

ABSTRACT

The determination of the texture in the carbonate rocks examined by microscope is important in the geological researches. Similar to oil drillings operations, quick determination of the rock samples is possible using image processing techniques and artificial neural networks. A previous study using this method when the limestone samples, in Dunham (1962) classification as mudstone, vackestone, packstone, grainstone of the sample by using artificial neural networks at a rate of 93% of the texture may be determined as accurately have been published. In this study, a similar method has been applied to the sample rocks known as Akveren formation located at İzmit and around. Using the samples from Akveren formation, 45 units with thin sections were made. The photos of thin cross-section were taken, then these pictures have been processed on the computer using MATLAB software. During the image-processing, "Sobel" filter was used. Then, by using artificial neural networks, the samples were examined in order to classify.

GİRİŞ

Yapay sinir ağları ve görüntü işleme yöntemleri, yerbilimlerindeki birçok konuda yakın zamanlarda kullanılmaya başlamıştır. Mikroskopta ince kesitler üzerindeki doku tanımlamaları için görüntü işleme ve yapay sinir ağlarının kullanılması ile ilgili yapılan çalışmalar da yayınlanmıştır. Bu çalışmalardan biri de Marmo ve diğ. (2005) makalesidir. Marmo ve diğ. (2005), Alt Kretase döneminde oluşan İtalya'daki San Lorenzello sığ su karbonatlarından alınan kayaç örnekleri üzerinde çalışmıştır. Bu makalede, San Lorenzello karbonatlarından alınan 215 adet kayaç örneklerinin ince kesitleri, mikroskop altında incelenmiş, Dunham'ın (1962) yaptığı karbonatlı kayaç sınıflamasını temel alarak adlandırılmıştır.

¹KOÜ., Mühendislik Fakültesi, Jeoloji Mühendisliği Bölümü, Umuttepe Yerleşkesi, İZMİT-KOCAELİ
e-mail: scakir@kocaeli.edu.tr.

²KOÜ., Mühendislik Fakültesi, Mekatronik Mühendisliği Bölümü, Umuttepe Yerleşkesi, İZMİT-KOCAELİ
e-mail: hmertunc@kocaeli.edu.tr, e-mail: hocak@kocaeli.edu.tr.

Bu sınıflamada kullanılan bağlamtaşı sınıfındaki örnekler kullanılmamıştır. Diğer 4 grupta yer alan örnekler ise, görüntü işleme yöntemleri ve yapay sinir ağlarını kullanarak, mikroskop altındaki tanımlama ile ne kadar uyumlu olduğunu test edilmiştir.

YÖNTEMİN UYGULANIŞI

Bu makalenin konusu olan çalışmada, İzmit ve çevresinde yüzeyleyen Akveren formasyonundan alınan killi kireçtaşı, marn örneklerinden yapılan ince kesitler kullanılmıştır. Bu ince kesitlerin polarizan mikroskopu görüntülerinin fotoğraflarının çekilmesi ve bu fotoğrafların görüntü işleme teknikleri ile sayısal veriler haline dönüştürülmesi ve daha sonra yapay sinir ağları ile bu verilerin değerlendirilerek bu fotoğraftaki görüntünün Dunham'ın (1962) sınıflamasında hangi grup içinde olduğu tahmin edilmeye çalışılmıştır.

GÖRÜNTÜ İŞLEME TEKNİKLERİ

Polarizan mikroskoptan çekilen ince kesit görüntüleri daha sonra görüntü işleme teknikleri ile değerlendirilmiştir. Bunlar:

Görüntüyü gürültüden arındırmak için

- 1- Medyan filtre uygulanmıştır. (3x3'lük)
- 2- Sobel filtresi kullanılarak kenar görüntüsü elde edilmiştir.
- 3- Görüntü siyah-beyaza çevrilmiştir.

Şu öznelikler kullanılmıştır:

- 1- Görüntüdeki en sık tekrarlanan gri tonlara sahip piksellerin yüzdesi,
- 2- Sobel filtresi sonrası elde edilen kenar görüntüsündeki beyaz piksellerin (kenar piksellerinin) yüzdesi,
- 3- Siyah-beyaz görüntüdeki beyaz piksellerin oranı,
- 4- Siyah-beyaz görüntüdeki bölge sayısı,
- 5- Siyah-beyaz görüntüdeki çevre piksellerinin oranı,
- 6- 250 pikselden büyük bölgelerin sayısı,

YAPAY SİNİR AĞLARI

Yapay sinir ağları (YSA), insan doğasını araştırma ve taklit etme çabalarının en son ürünlerinden bir matematiksel yöntem olarak ortaya çıkmıştır. Bilim adamları, beynin nörofiziksel yapısını göz önüne almışlar, beynin davranışlarını tam olarak modellemeye çalışmışlardır. Modelleme için çeşitli yapay hücre ve ağ modelleri geliştirmişler (Ertunç, 2006).

Yapay sinir ağları, birbirlerine bağlanmış birçok işlem biriminden (nöronlar) oluşan matematiksel sistemlerdir (Şekil 1). Bir işlem birimi, diğer nöronlardan sinyalleri alır, bunları birleştirir. İşlem birimleri kabaca gerçek nöronlara karşılık gelir ve bir ağ üzerinde birbirlerine bağlanırlar, bu yapı da sinir ağlarını oluşturur. Yapay sinir ağları, yapısı bilgi işleme yöntemindeki farklılık ve uygulama alanları nedeniyle çeşitli dallarının da kapsam alanına girmektedir.

Yapay sinir ağlarının özellikleri

Yapay sinir ağları, hesaplama ve bilgi işleme gücünü, paralel dağılmış yapısından, öğrenebilme ve genelleme yeteneğinden almaktadır. Genelleme, eğitim ya da öğrenme sürecinde karşılaşılmayan girişler için de yapay sinir ağlarının uygun tepkileri üretmesi olarak tanımlanır. Bu özellikler, yapay

sinir ağlarının problemleri çözebilme yeteneğini gösterir. Yapay sinir ağları, aşağıdaki özellikleri nedeniyle birçok alanda uygulanmaktadır.

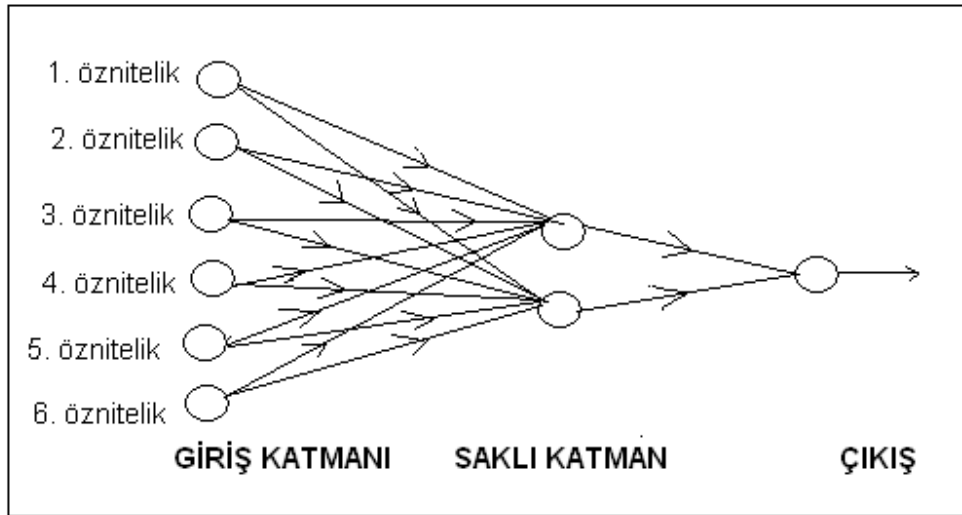
Doğrusal Olmama: Yapay sinir ağlarının temel işlem elemanı olan hücre, doğrusal değildir. Dolayısıyla hücrelerin birleşmesinden meydana gelen Yapay sinir ağları da doğrusal değildir ve bu özellik bütün ağa yayılmış durumdadır. Bu özelliği ile de doğrusal olmayan problemlerin çözümünde önemli bir araçtır.

Öğrenme: Yapay sinir ağlarının istenilen davranışı gösterebilmesi için uygun olarak ayarlanması gerekir. Bu, hücreler arasında doğru bağlantıların yapılması ve bağlantıların uygun ağırlıklara sahip olması demektir. Yapay sinir ağlarının karmaşık yapısı nedeniyle bağlantılar ve ağırlıklar önceden ayarlanarak verilmaz. Yani yapay sinir ağları, eğitim örneklerini kullanarak problemi öğrenir.

Genelleme: Yapay sinir ağları, problemi öğrendikten sonra eğitim sırasında karşılaşmadığı test örnekleri için de arzu edilen tepkiyi üretebilir. Örneğin, karakter tanıma amacıyla eğitilmiş bir yapay sinir ağları, bozuk karakter girişlerinde de doğru karakterleri verebilir ya da bir sistemin eğitilmiş yapay sinir ağları modeli, eğitim sürecinde verilmeyen giriş sinyalleri için de sistemle aynı davranışı gösterebilir.

Uyarlanabilirlik: İlgilendiği problemdeki değişikliklere göre ağırlıklarını ayarlar. Yani, belirli bir problemi çözmek amacıyla eğitilen Yapay sinir ağları, problemdeki değişimlere göre tekrar eğitilebilir ve değişimler devamlı ise gerçek zamanda da eğitime devam edilebilir. Uyarlamalı örnek tanıma, sinyal işleme, sistem tanılama ve denetim gibi alanlarda etkin olarak kullanılır.

Hata Toleransı: Yapay sinir ağları, çok sayıda hücrenin çeşitli şekillerde bağlanmasından oluşmuştur. Bu ağdaki bilgi, ağdaki bütün bağlantılar üzerine dağılmış durumdadır. Bu nedenle, eğitilmiş bir yapay sinir ağlarının bazı bağlantılarının veya bazı hücrelerin etkisiz durumda olması, ağın doğru bilgi üretmesini önemli ölçüde etkilemez. Bu nedenle, diğer yöntemlere göre hatayı tolere etme yeteneği son derece yüksektir (Ergezer ve diğ. 2003).



Şekil 1. Yapay sinir ağlarının çalışma prensibi
Figure 1. Working principle of artificial neural networks

YAPAY SİNİR AĞLARININ KULLANIM ALANLARI

Yapay sinir ağları; ses tanıma, yazılan karakteri tanıma, robot kontrolleri, resim işleme ve yüz tanıma sistemlerinde çok sık olarak kullanılmaktadır. İnsanın (özellikle insan beyni ve algı sistemi) modellenmesi, yüz tanıma sistemleri son yıllarda önem kazanmıştır. Sanayi alanında arıza analizi ve tespiti; tıp alanında EEG, ECG sinyallerinin analizi, kanserli hücrelerin analizi, transplantasyon zamanlarının optimizasyonu; savunma sanayinde silahların otomasyonu, hedef izleme, nesnelere görüntüleme, ayırma, tanıma konularında yararlanılır. Fabrikalarda üretim sistemlerinin optimizasyonu, ürün analizi ve tasarımı, kalite analizi gibi konularda kullanılmaktadır (Hagan ve diğ. 1996).

KİREÇTAŞLARINDA DOKU ANALİZİ

Doku analizinin ilk basamağı orjinal depolanma ortamının tanımlanmasıdır. Bu konuda birçok sınıflandırma yapılmıştır. Bu sınıflandırmaların önemli olanlarından biri de Dunham (1962) sınıflandırmasıdır. Dunham, karbonat kayaları sınıflandırırken depolanma sonrası oluşan dokuyu göz önüne alarak sınıflama yapmıştır. Bu sınıflamada karbonat kayaları depolanma dokusu tanınabilenler ve tanınamayanlar olarak ikiye ayrılmıştır. Çökelme sırasında oluşan dokusu tanınamayanlar kristalli karbonatlardır. İlk dokusu tanınanlar ise çamurtaşı, vaketaşı, istiftaşı, tanetaşı ve bağlamtaşıdır. Çamurtaşı (mudstone) % 10'dan daha az tane bulundurur. Çamurun oldukça fazla olması oluşma ortamında enerjinin az olduğu anlamına gelir. Tane oranı % 10'dan daha çok olanlar ise vaketaşidir (wackestone). Tane oranının artması ile tane destekli bir doku görüldüğü zaman istiftaşı (packstone) oluştuğu anlaşılır. Tane destekli olması enerjinin arttığını göstermektedir. Çamurun hemen hemen hiç olmaması tanetaşının (grainstone) oluştuğunu gösterir. Bağlamtaşı (boundstone) kayacın oluşma sırasında birbirine bağlanarak oluştuğunu gösterir.

Bu makalenin konusu ile ilgili olarak yapılan çalışmalardan birisi de Marmo ve diğ. (2005) makalesidir. Bu makalede; ilksel dokusu tanınabilen karbonat kayalarının (bağlamtaşı hariç) yapay sinir ağları yardımıyla kayaç örneklerinin olması gereken grubunu tahmin edilmeye çalışılmış, toplam 215 adet ince kesit kullanılmış, bu kesitlerden 201'i doğru tahmin edilmiştir. Bu kesitlerin 22'si çamurtaşı, 100 tanesi vaketaşı, 67 tanesi istiftaşı ve 26 tanesi de tanetaşidir. Bu tahminlerin doğruluk oranı % 93.5'tir. Tek tek gruplar bazında hesaplandığında şöyledir: 22 adet çamurtaşı örneğinin sınıfının hepsi doğru tahmin edilmiş olup, başarı oranı % 100'dür. 100 adet vaketaşı örneğinin 98'i doğru tahmin edilmiş, 2 tanesi ise istiftaşı olarak bulunmuştur. 67 adet istiftaşı örneğinin 57'si doğru tahmin edilmiş, 10 adet örnek ise vaketaşı olarak bulunmuştur. 26 tanetaşı örneğinden 24 tanesi doğru tahmin edilmiş, 2 örnek ise istiftaşı olarak bulunmuştur.

AKVEREN FORMASYONU ÖRNEKLERİ ÜZERİNDE GÖRÜNTÜ İŞLEME VE YAPAY SİNİR AĞLARI ÇALIŞMASI

Bu çalışmada, İzmit ve çevresinde yüzeyleyen Akveren formasyonu kayaçlarından alınan 45 adet ince kesit örneği kullanılmıştır. Bu örneklerden 7 tanesi çamurtaşı, 9 tanesi vaketaşı, 14 tanesi istiftaşı, 15 tanesi de tanetaşidir. Görüntü işleme teknikleri ve yapay sinir ağları kullanılarak yapılan sınıflamada Dunham (1962) sınıflamasında kullanılan 4 grup bu çalışmada tam olarak ayrılamamıştır. Bu nedenle görüntü işleme çalışmaları sonucunda oluşan görüntülere göre vaketaşı ve istiftaşı örneklerinin ince kesitlerinin görüntü işleme teknikleriyle değerlendirilmesi sonucunda bu iki grubun özneliklerinin bazı örneklerde birbirine çok yakın olması nedeniyle bu iki grup tek grup olarak kabul edilmiştir. Bunun sonucunda 4 grup yerine 3 grup kabul edilerek çalışılmıştır.

Bu makale kapsamında yapılan görüntü işleme çalışmasında şu öznelikler kullanılmıştır:

1- Görüntüdeki en sık tekrarlanan gri tonlara sahip piksellerin yüzdesi: Çamurtaşlarında bu yüzde

- düşük, tanetaşlarında ise fazladır.
- 2- Sobel filtresi sonrası elde edilen kenar görüntüsündeki beyaz piksellerin (kenar piksellerinin) yüzdesi: Çamurtaşlarında az, tanetaşlarında fazladır.
 - 3- Siyah-beyaz görüntüdeki beyaz piksellerin oranı: Tanetaşlarında fazla, çamurtaşlarında azdır.
 - 4- Siyah-beyaz görüntüdeki bölge sayısı: Tanetaşlarında fazla, çamurtaşlarında azdır.
 - 5- Siyah-beyaz görüntüdeki çevre piksellerinin oranı: Tanetaşlarında fazla, çamurtaşlarında azdır.
 - 6- 250 pikselden büyük bölgelerin sayısı: Tanetaşlarında fazla, çamurtaşlarında yok, vaketaşları ve istiftaşlarında ise az bulunur.


Görüntü işleme teknikleri ile her bir kayaç örneğine ait 6 adet öznitelik elde edilmiştir. Bu öznitelikler, çalışmada geliştirilen yapay sinir ağlarına giriş olarak verilmiştir. Sistemin çıkışı olarak gruplara sırasıyla -1, 0 ve 1 değerleri verilmiştir. Şöyle ki, çamurtaşı grubundaki örnekler için -1, vaketaşı ve istiftaşı için 0 ve tanetaşı için +1 çıkış değerleri üretilmiştir. Böylelikle her bir taş örneği için 6 adet öznitelikten oluşan giriş vektörü ve -1, 0 veya 1 değerinden oluşan bir çıkış değeri ile giriş/çıkış ikilisi elde edilmiştir. Bu veriler arasından rasgele seçilen 27 adet giriş/çıkış değerleri yapay sinir ağlarının eğitimi amacı ile kullanılmış ve yapay sinir ağlarına dayalı bir tahmin modeli geliştirilmiştir. Geri kalan 18 adet giriş/çıkış örneği ise geliştirilen modeli test amacı için kullanılmıştır.

Geliştirilen yapay sinir ağı modeli Şekil 1’de gösterildiği gibi 6 adet nörondan oluşan giriş katmanı, 2 adet nörondan oluşan bir saklı katman ile incelenen taş örneğinin bulunduğu grubu gösteren ve tek bir değeri gösteren nörondan oluşan çıkış katmanlarının bir araya gelmesiyle elde edilmiştir. Yapay sinir ağları tabanlı modelin tahmin başarısı ağda kullanılan katman ve nöron sayısı gibi ağ karakteristiklerine bağlıdır [Ertunç ve Hoşöz, 2008]. Ancak bu sayıların belirlenmesi için literatürde geliştirilmiş kesin bir yöntem yoktur. Bu çalışmada da deneme yanılma yöntemi ile saklı katman sayısı ve saklı katmandaki nöron sayısı belirlenmiştir. Az sayıda veri ile (giriş/çıkış ikilisi ile) çalışıldığı için tek saklı katman ve iki nöron, tatmin edici bir performans için yeterli olmuştur. Yapay sinir ağı oluşturulurken saklı katmandaki nöronlar için aktivasyon fonksiyonu olarak hiperbolik tanjant sigmoid fonksiyonu seçilmiştir. Bu fonksiyon [-1,1] aralığında tanımlanmış ‘S’ şeklinde doğrusal olmayan bir fonksiyondur. Ağ çıkışında incelenen taş örneklerinin grupları -1, 0 ve 1 olarak atandığı için seçilen hiperbolik tanjant sigmoid aktivasyon fonksiyonu diğer bilinen fonksiyonlardan daha iyi bir performans vermiştir.


Bu çalışmada ağın eğitimi aşamasında standart bir yöntem olan geriye yayılım algoritması kullanılmıştır. Bu algoritma vasıtasıyla her bir kayaç örneğinden görüntü işleme teknikleri ile elde edilen 6 adet öznitelik, taşın bulunduğu gruba göre -1, 0 ve 1 sayılarını üretecek şekilde eğitilmiştir. Giriş ile çıkış arasındaki bağlantının kurulması esnasında nöronlar arasındaki bağlantıyı sağlayan ağırlık katsayıları Levenberg-Marquardt algoritması ile ayarlanmıştır. Eğitim esnasında ağ çıkışları ile hedef çıkış arasındaki farklar (hata değerleri) geriye yayılım algoritması ile her bir iterasyonda azaltılır ve nihayetinde Yapay Sinir Ağı istenen çıkışı verecek şekilde ağırlık katsayılarını ayarlamış olur. Bu aşama bittikten sonra, eğitim esnasında kullanılmayan girişler ağa verilerek kurulan sistemin performansı test edilir. Tüm bu işlemler Matlab paket programı altında çalışan Neural Network Toolbox isimli araç kutusunda gerçekleştirilmiştir.

Sistemin performansı Şekil 5’te görülmektedir. Yukarıda açıklandığı gibi eldeki 45 adet veriden 27 adeti eğitim aşamasında, 18 adeti ise test amacıyla kullanılmıştır. Bu amaçla çamurtaşından 3 adet, vaketaşı ve istiftaşından 9 adet ve tanetaşından ise 6 adet örnek alıp test edilmiştir. Şekil 5’te hedeflenen çıktılar ‘o’ sembol ile gösterilirken kestirilen (tahmin edilen) değerler yani ağın çıktuları ise ‘x’ sembolü ile temsil edilmiştir. Her bir grup için bir tolerans aralığı belirlenmiştir. Şöyle ki, çamurtaşı için hedeflenen değer -1 iken -1.5 ile -0.5 arasında yapılan tahminler de doğru kabul

edilmiştir. Benzer şekilde vaketaşı ve istiftaşı grubu için -0.5 ile +0.5 arasında yapılan tahminler ve tanetaşı için ise +0.5 ile +1.5 arasındaki tahminler tolerans sınırları içinde kaldığı kabul edilip




Şekil 2. Mikroskop görüntüleri (tek nikol x 25), (A) Çamurtaşı, (B) Vaketaşı, (C) Tanetaşı
Figure 2. Microscope images (parallel nicol x 25), (A) Mudstone, (B) Wackestone, (C) Grainstone



Şekil 3. İnce kesit görüntülerinin Sobel kenar filtresi kullanıldığında görüntüsü. (A) Çamurtaşı, (B) Vaketaşı, (C) Tanetaşı

Figure 3. Thin section images using a Sobel edge filter image. (A) Mudstone, (B) Wackestone, (C) Grainstone

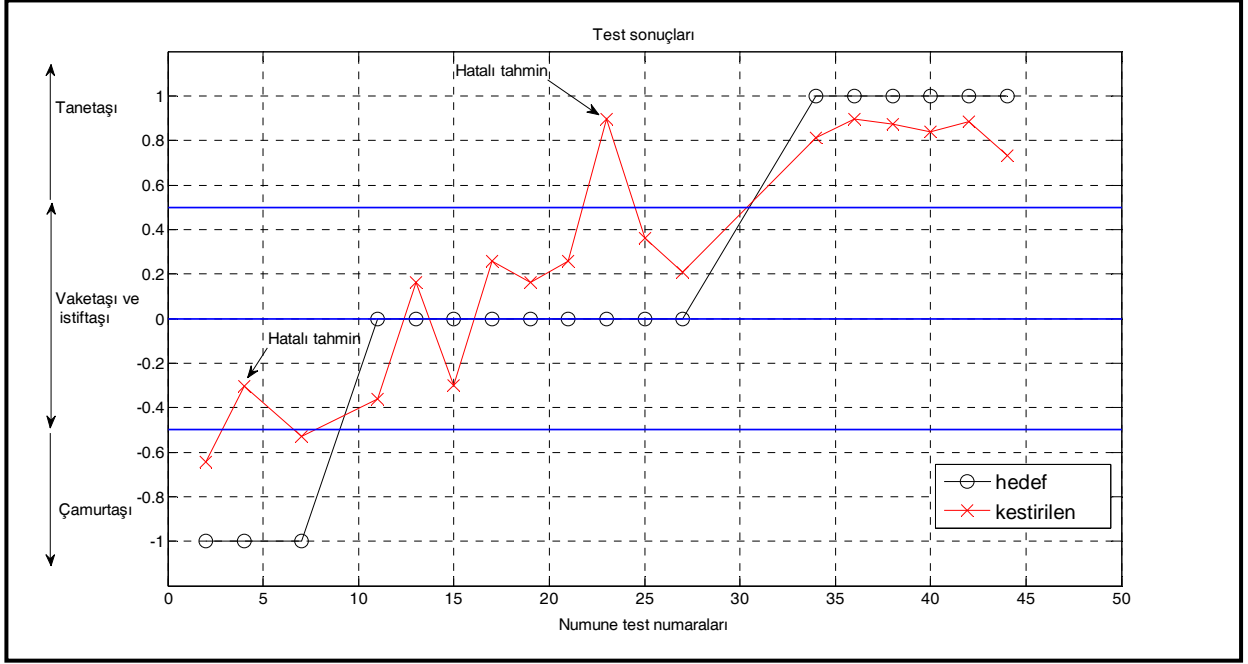
kurulan ađın giriřteki kayaç örneklerini ayırt edilebildiđi anlamında deđerlendirilmiřtir. Bu bađlamda, řekil 5'te de görüldüđu gibi çamurtařı grubunda 1 adet ve vaketařı-istiftařı grubunda ise



yine 1 adet örnek yanlış tahmin edilmiřtir. 18 adet örnekten 2 adet örnek yanlış kestirildiđi için ađın % 89 oranla dođru çalıřtıđı hesaplanmıřtır.

řekil 4. İnce kesitlerin siyah-beyaz görüntüsü. (A) Çamurtařı, (B) Vaketařı, (C) Tanetařı

Figure 4. Black-white image of thin sections. (A) Mudstone, (B) Wackestone, (C) Grainstone



Şekil 5. Akveren formasyonu örneklerinin yapay sinir ağı sonuçları

Figure 5. Artificial neural network study results of Akveren formation samples

SONUÇLAR

Dunham (1962) tarafından isimlendirilen çamurtaşı, vaketaşı, istiftaşı ve tanetaşı örnekleri bu çalışmada vaketaşı ve istiftaşı gruplarının birleştirilmesi ile 3 grup olarak incelenmiştir. Çünkü Akveren formasyonu vaketaşı ve istiftaşı örneklerinin bazılarının dokuları birbirine benzer değerlerdedir. Bazı vaketaşı örneği istiftaşı örneğine benzer, ya da istiftaşı örneği vaketaşına yakın özellikler göstermektedir. Bu iki doku grubu birleştirilmiş ve 3 grup olarak incelenmiştir. Eğitim amaçlı kullanılan örneklerde, iki adet örnek dışında diğer örneklerin doku grubunun doğru tahmin edildiği görülmektedir (Şekil 5). Hatalı olan örneklerden biri çamurtaşı, diğeri ise vaketaşı ve istiftaşı grubundandır. Buna göre tüm gruplar için doğruluk oranı % 89 olarak bulunmuştur. Bu çalışmada çamurtaşı grubunun tahmininde diğer gruplara göre çok daha fazla yanlışlara neden olmuştur. Bu hatanın örnek sayısının (7 adet) az olması nedeniyle açıklanabilir.

KAYNAKLAR:

DUNHAM, R. J., 1962. Classification of Carbonate Rocks According to Depositional Texture. In Classification of Carbonate Rocks, W.E. Ham. (ed.), 108-121. Amer. Ass. Petrol. Geol. Mem. Tulsa, Oklahoma.

ERGEZER, H., DİKMEN, M. ve ÖZDEMİR, E., 2003. Yapay sinir ağları ve tanıma sistemleri. PİVOLKA, 2(6), 14-17.

ERTUNÇ, H. M., 2006. Prediction of the Pool Boiling Critical Heat Flux Using Artificial Neural Network, IEEE Transactions on Components and Packaging Technologies, Vol.29, No.4, p.770-777.

ERTUNÇ, H. M., HOŞÖZ, M., 2008. Comparative analysis of an evaporative condenser using artificial neural network and adaptive neuro-fuzzy inference system, *International Journal of Refrigeration*, vol. 31, p.1426-1436.

HAGAN, M.T., DEMUTH, H.B., BEALE, M., 1996. *Neural Network Design*, PWS Publishing Company, Boston, M.A.

MARMO, R., AMODÍO, S., TAGLIAFERRI, R., FERRERI, V., LONGO, G., 2005. Textural Identification of Carbonate Rocks by Image Processing and Neural Network: Methodology Proposal and Examples. *Computers and Geosciences*. pp. 649-659.