




GEOMATİK

<https://dergipark.org.tr/tr/pub/geomatik>

e-ISSN 2564-6761



Yere Nüfuz Eden Radar B Tarama Görüntülerinin Az Parametreye Sahip Konvolüsyonel Sinir Ağı İle Değerlendirilmesi

Umut Özkaya^{1*}, Levent Seyfi¹

¹Konya Teknik Üniversitesi, Mühendislik ve Doğa Bilimleri Fakültesi, Elektrik-Elektronik Mühendisliği Bölümü, Konya, Türkiye

Anahtar Kelimeler

Yere nüfuz eden radar
Konvolüsyonel sinir ağları
K-En yakın komşuluk
Ön eğitilmiş konvolüsyonel
sinir ağları

ÖZ

Bu çalışmada, Yere Nüfuz eden Radar (YNR) B tarama görüntülerinin analizi için az parametre sayısına sahip K-En Yakın Komşuluk (K-EYK) algoritma tabanlı bir Konvolüsyonel Sinir Ağı (KSA) yapısı önerilmiştir. Önerilen KSA yapısı içerisinde farklı filtre boyutuna ve sayına sahip beşer adet konvolüsyon katmanı bulunmaktadır. Aynı zamanda blok adı verilen yapı ile önerilen KSA modelinin yapısı daha da görselleştirilmiştir. Karşılaştırmalı analiz çerçevesinde önerilen KSA modeli ön eğitilmiş KSA modelleri ile beraber değerlendirilmiştir. Analiz metrikleri olarak doğruluk, keskinlik, duyarlılık ve F1 skoru kullanılmıştır. Önerilen KSA yapısı, YNR cihazı tespitinde %97.16 doğruluk, %97.31 keskinlik, %97.04 duyarlılık ve %97.18 F1 skoru; tarama frekansı tespitinde %94.88 doğruluk, %95.02 keskinlik, %95.49 duyarlılık ve %95.24 F1 skoru; toprak çeşidi tespitinde %90.63 doğruluk, %90.50 keskinlik, %90.83 duyarlılık ve %90.66 F1 skoru metrik değerlerine sahiptir. Önerilen KSA yapısı YNR cihaz tespiti ve tarama frekansı tespitinde en yüksek performansı gösterirken toprak çeşidi tespitinde ön eğitilmiş KSA yapıları ile beraber en yüksek üçüncü performansı sergilemiştir. Karşılaştırmalı analizler önerilen KSA yapısının düşük parametre sayısı ile yüksek sınıflama yüzdesi elde ettiğini göstermiştir.

Evaluation of Ground Penetrating Radar B Scan Images via Convolutional Neural Network with Low Parameters

Keywords

Ground penetrating radar
Convolutional neural
network
K-Nearest neighborhood
Pre-trained convolutional
neural network

ABSTRACT

In this study, a K-Nearest Neighborhood (KNN) algorithm based Convolutional Neural Network (CNN) structure with low number of parameters was proposed for the analysis of Ground Penetrating Radar (GPR) B scan images. Within proposed CNN structure, there are five convolution layers with different filter sizes and numbers. At the same time, the structure of proposed CNN model with the structure called block is further visualized. The proposed CNN model within the framework of comparative analysis was evaluated together with pre-trained CNN models. Accuracy, precision, recall and F1 score were used as classification metrics. Proposed CNN structure obtained performance with 97.16% accuracy, 97.31% precision, 97.04% recall and 97.18% F1 score for detection of GPR device; 94.88% accuracy, 95.02% precision, 95.49% recall and 95.24% F1 score to classify scanning frequency; 90.63% accuracy, 90.50% precision, 90.83% recall and 90.66% F1 score metric values to determine soil type. While proposed CNN structure showed the highest performance in GPR device detection and scanning frequency determination, it showed the third highest performance together with the pre-trained CNN structures in soil type determination. Comparative analysis has shown that the proposed CNN structure achieves a high classification performance with a low number of parameters.

*Sorumlu Yazar

Kaynak Göster (APA)

(uozkaya@ktun.edu.tr) ORCID ID 0000-0002-9244-0024
(lseyfi@ktun.edu.tr) ORCID ID 0000-0002-8698-5140

Özkaya, U. & Seyfi, L. (2021). Yere Nüfuz Eden Radar B Tarama Görüntülerinin Az Parametreye Sahip Konvolüsyonel Sinir Ağı İle Değerlendirilmesi. Geomatik, 6(2), 84-92, DOI: 10.29128/geomatik.703218

1. GİRİŞ

Yere Nüfuz Eden Radarlar (YNR), arkeolojik çalışmalar, inşaat mühendisliği ve çeşitli jeofizik uygulamalarında yaygın olarak kullanılmaktadır (Shihab vd. 2005). YNR, elektromanyetik dalga yayılımı prensibi ile çalışır. Elde edilen verilere radargram adı verilirken grafiklerle şematize edilir. Yorumlanması oldukça zor olan radargram verilerinin analizinde, konusunda uzman kişilerin bilgisine ihtiyaç duyulur. Literatürdeki çalışmalar incelendiğinde gömülü nesnelere analiz ve saha analizlerinde çeşitli yaklaşımlar sunulmuştur. Gader vd. gerçekleştirdikleri çalışmada patlayıcı malzemelerin tespiti için YNR cihazı ile elde edilen B tarama görüntülerinin analizinde Gizli Markov Modeli (GMM) kullanılmışlardır. Önerilen yöntem, üç farklı bölgeden elde edilen B tarama görüntülerinde değerlendirilmiş ve genelleme yeteneğinin oldukça yüksek olduğu görülmüştür (Gader vd. 2001). Gader vd. 3 boyutlu YNR tarama görüntüleri üzerinden mayın tespitini gerçekleştirmeye çalışmışlardır. Önerdikleri kural tabanlı yöntem sayesinde yüksek bir performans ile mayınların varlığını tespit edebilmişlerdir (Gader vd. 2004). Frigui vd. yapmış oldukları çalışmada kara mayınlarının tespitinde hibrid bir yöntem sunmuşlardır. Yöntem içerisinde ön işleme birimi, GMM dedektörü ve yanlış alarmı azaltmak amacıyla düzenleyici eğitim bileşeni bulunmaktadır. Gerçek zamanlı olarak çalışabilen bu sistem farklı test sahalarında %10-50 arasında bir performans sağlamıştır (Frigui vd. 2005). Manandher vd. çalışmalarında GMM modelinin performansını artırmak amacıyla çoklu örnek öğrenme tekniğini modele entegre etmişlerdir. Önerilen yöntem sentetik ve kara mayınlarının bulunduğu test sahalarından standart GMM modeline göre daha yüksek performans göstermiştir (Manandhar vd. 2015). Kovalenko vd. yapmış oldukları çalışmadan bir boyutlu YNR A tarama sinyallerini analiz ederek plastik kaplı kara mayınlarını tespit etmeye çalışmışlardır. Gömülü nesne bilgilerini içeren referans dalga formu ile sinyal içerisinde nesnenin varlığını araştırmışlardır (Kovalenko vd. 2007). Pasolli vd. yapmış oldukları çalışmada sunmuş oldukları örüntü tanıma yöntemi sayesinde gömülü nesnelere algılanması ve tanınması amaçlamışlardır. Yöntemde ilk olarak görüntü eşikleme işlemi ile gömülü nesnelere arka plandan çıkarılması sağlanır. Genetik algoritma ile özellik çıkarılarak Destek Vektör Makinesi (DVM) ile gömülü nesne sınıflaması gerçekleştirilir (Pasolli vd. 2009). El-Mahallawy vd. yapmış oldukları çalışmada B tarama görüntülerinden Ayrıklı Fourier Dönüşümü ile elde ettiği özellikleri DVM ile sınıflayarak gömülü nesnelere malzeme tespitini gerçekleştirmişlerdir (El-Mahallawy vd. 2013). Singh vd. YNR B tarama görüntülerinde gömülü nesnelere tespitini sağlamak için yapay sinir ağı tabanlı bir yaklaşım kullanmışlardır. Yöntemde ön işleme algoritması kullanılarak görüntü içerisinde gürültü ve dağınıklıklar giderilmiştir. Sonrasında ise gömülü

nesnelere algılamak amacıyla yapay sinir ağı tekniğinden yararlanılmıştır (Singh vd. 2013). Benedetto vd. eğri uydurma yöntemi ile buz içerisindeki çatlakları analiz etmişlerdir (Benedetto vd. 2011).

Uzaktan algılama uygulamalarında son zamanlarda gerçekleştirilen çalışmalar derin öğrenme tabanlıdır. Derin öğrenme yöntemleri olarak kullanılan Konvolüsyonel Sinir Ağları (KSA), yapay sinir ağlarının gelişmiş bir versiyonudur. 1990'lı yıllarda KSA yöntemi önerilmesine rağmen mevcut donanımlar, yöntemin ağır hesaplamalarını gerçekleştirememiştir. Gelişen teknolojiyle beraber 2012 yılından bu yana derin öğrenme yöntemleri nesne algılama ve tanıma problemleri başta olmak üzere birçok alanda kullanılmaya başlanmıştır (Krizhevsky vd. 2012).

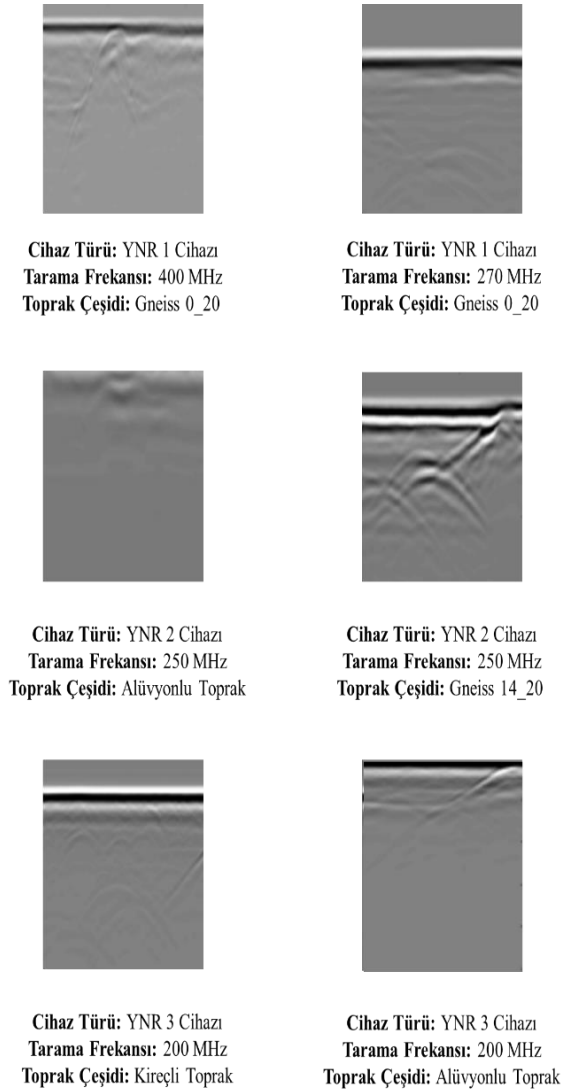
Bu çalışmada YNR B tarama görüntüleri daha etkin bir şekilde analizi için az parametreye sahip KSA yapısı tasarlanmıştır. Önerilen KSA yapısında standart ön eğitilmiş KSA yapılarından farklı olarak sınıflama için K-EYK algoritması kullanılmıştır. Elde edilen sonuçlar değerlendirildiğinde önerilen KSA yapısı ön eğitilmiş KSA yapılarına göre yüksek performans göstermiştir. Çalışma toplamda dört bölüme ayrılmıştır. 1. Bölüm, giriş olarak adlandırılıp literatür çalışmalarından bahsedilmiştir. 2. Bölüm ise materyal ve yöntem kısmıdır. 3. Bölüm, elde edilen bulgular yer almaktadır. 4. Bölümde elde edilen sonuçlar ve tartışma bulunmaktadır.

2. MATERYAL ve YÖNTEM

2.1. Veri Seti Tanımlaması

Çalışma kapsamında kullanılan ve YNR B tarama görüntülerinden oluşan veri seti, test sahalarından elde edilen ölçümler ile oluşturulmuştur. Ölçümlerde birbirinden farklı üç YNR cihazı kullanılmıştır. Cihazları birbirinden ayırt edebilmek adına YNR 1, YNR 2 ve YNR 3 adları verilmiştir. YNR 1 ABD firması olan Geophysical Survey Systems, Inc (GSSI) tarafından tasarlanmıştır. YNR 2 cihazı ise İsveç firması MALA tarafından kullanıma sunulmuştur. YNR 3 cihazı ise Ingegneria Dei Sistemi (IDS) adı altında bir İtalyan firması tarafından üretilmiştir. Belirtilen YNR cihazları okuz farklı frekansta tarama işlemlerini gerçekleştirebilmektedirler. Bu frekanslar sırasıyla 200 MHz, 250 MHz, 270 MHz, 350 MHz, 400 MHz, 500 MHz, 600 MHz, 800 MHz ve 900 MHz'dir. YNR cihazları dört farklı test sahasında ölçüm gerçekleştirmiştir. Test sahaları alüvyonlu, kireçli, Gneiss 14_20 ve Gneiss 0_20 olmak üzere farklı özellikler içermektedir. Alüvyonlu toprağın bağıl dielektrik sabiti $\epsilon_r=13$ olup saha içerisindeki Elektromanyetik (EM) dalgaların zayıflaması 15 ile 45 dB/m arasında gerçekleşmektedir. YNR cihazının nüfuz etme derinliği alt frekansta 1.5 m olup üst frekansta 1 m'dir. Kireçli test sahasında bağıl dielektrik sabiti $\epsilon_r=6$ olup EM dalga zayıflamaları 6 ile 20 dB/m civarındadır. YNR cihazının nüfuz etme

derinliği alüvyonlu toprakta olduğu gibi alt frekansta 1.5 m üst frekansta ise 1 m'dir. Gneiss 14_20 ve Gneiss 0_20 elektriksel özellikleri sırasıyla $\epsilon_r=3$ ve $\epsilon_r=5.5$ 'dir. EM dalgaların zayıflaması Gneiss 14_20 test sahası için 1.5 ile 4.5 dB/m, Gneiss 0_20 test sahası için 9 ile 27 dB/m arasındadır. YNR cihazları Gneiss 14_20 test sahası için en az 4.5 m kadar nüfuz edebilmektedir. Gneiss 0/20 test sahasında YNR cihazları alt frekansta 2.5 m, üst frekansta 1.5 m nüfuz etme derinliğine sahiptir. İlgili YNR cihazlarından ve test sahalarından elde edilen YNR B tarama görüntüsü toplamda 8505 adettir. Çalışma kapsamında oluşturulan veri setinde bulunan bazı YNR B tarama görüntüleri Şekil 1'de bulunmaktadır.



Şekil 1. YNR B Tarama Görüntü Örnekleri

2.2. Derin Öğrenme

Makine öğrenmesi kapsamında geliştirilen derin sinir ağları, 2007 yılında Geoffrey Hinton tarafından optimizasyon yöntemleri sayesinde etkin bir şekilde eğitimi gerçekleştirilmiştir (Hinton 2007). Son zamanlarda kullanımı sıklıkla artan derin öğrenme birçok alanda uygulanmaya başlanmıştır. E-posta filtreleme, arama motoru eşleştirme, akıllı

telefonlar, sosyal medya, e-ticaret gibi birçok alanda derin öğrenmenin kullanımına örnek verilebilir. Yapay sinir ağlarının farklı bir türü olan derin sinir ağları çok katmanlı yapıya sahiptirler. Katman sayısı arttıkça KSA eğitimi için gereken veri sayısı da artmaktadır.

2.3. Konvolüsyonel Sinir Ağları

Konvolüsyonel Sinir Ağlarının (KSA) mimarisi incelendiğinde ileri beslemeli bir ağ yapısına sahip olduğu görülmektedir. Bu yapılar ağırlık paylaşım işlemini gerçekleştirerek hesaplama yükünü azaltırlar. Aynı zamanda görüntü içerisindeki uzamsal yapıları kodlamak için de tasarlanmışlardır. KSA yapıları, yükseklik, genişlik ve derinlik olmak üzere üç boyutlu bir yapıya sahiptir. Konvolüsyon filtreleri sayesinde giriş görüntüsünden özellik haritaları üretilir.

KSA yönteminde karşılaşılan en büyük problemler aşırı uyum ve doğrusallıktır. Önerilen derin öğrenme modeli eğitim verilerinde başarısı yüksek, test verilerinde başarısı düşük ise model eğitim verilerine aşırı uyum göstermiş olur. Aşırı uyum probleminin önüne geçmek amacıyla havuzlama ve kaçınma katmanından yararlanır. Havuzlama katmanı özellik indirgemek amacıyla kullanılırken kaçınma katmanı önemli özelliklerin seçiminde kullanılmaktadır. Bu sayede eğitim ve test verilerini genelleyebilecek özelliklerin seçimiyle aşırı uyum probleminin önüne geçilmiş olur. KSA yapısı içerisinde aktivasyon fonksiyonları yerleştirilerek doğrusallık probleminin önüne geçilmiş olur (Öztürk vd. 2019).

KSA yapısının temel bileşenleri konvolüsyon, havuzlama, aktivasyon fonksiyonu, kaçınma ve tam bağlı katmanlardır. Konvolüsyon katmanında güncellenebilen görüntü filtreleri bulunur. Bu katmanda iki boyutlu konvolüsyon işlemi gerçekleştirilir. Çıktı olarak ise özellik haritaları elde edilir. Özellik haritasının sayısını kullanan konvolüsyon filtre sayısı belirler. Görüntü içerisindeki kenar bilgilerin elde edilmesi için sıfır dolgusu uygulanabilir. Özellik haritalarında bulunan önemli özelliklerin seçilmesi amacıyla havuzlama katmanından yararlanır. Maksimum ve ortalama havuzlama katmanı olmak üzere iki çeşidi mevcuttur. Havuzlama katmanı özellik haritalarındaki belirli büyüklükteki pencereler içerisinde maksimum özelliği ve özelliklerin ortalamasını alarak farklı bir matrise aktarır. Aktivasyon fonksiyonları doğrusal olmayan fonksiyonlar içerir. Bu fonksiyonlar özellik haritalarına uygulanarak doğrusallık probleminin önüne geçilmiş olur. Kaçınma katmanı elde edilen özelliklerin gauss dağılımına bakılarak özelliklerin en önemlilerini bir sonraki katmana aktarır. Tam bağlı katmanlar içerisinde ağırlık ve bias değerleri ile tipik bir yapay sinir ağı modelini temsil eder. Son olarak ise sınıflama işlemi için yaygın olarak Softmax yapısı kullanılır. Softmax, olasılıksal sınıf tahminleyicisi olarak işlem yapar.

Konvolüsyon işlemi iki fonksiyon üzerinden gerçekleştirilir. t terimi zamanı, x(t) ifadesi ise elde edilen veriyi temsil ederse konvolüsyon işlemi aşağıdaki gibi tanımlanır:

$$S(t) = \int X(a)W(t-a)da \quad (1)$$

W(t) terimi ağırlıklandırma fonksiyonunu belirtir. Konvolüsyon işleminin diğer bir ifadesi ise şu şekildedir.

$$S(t) = (X * w)(t) \quad (2)$$

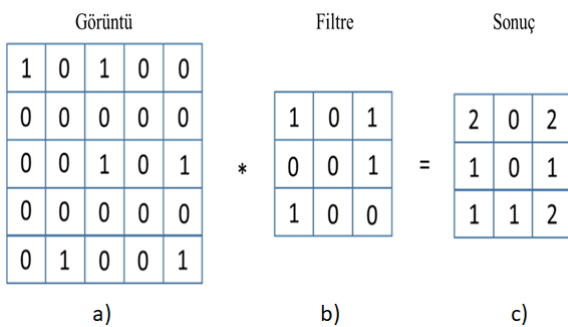
KSA mimarisinde Denklem 2’de bulunan x(t) ifadesi giriş, w(t) terimi de çekirdek ya da filtre matrisini temsil eder. S(t) ifadesi de konvolüsyon işlemi sonucunda elde edilen özellik matrisi adı verilir. t, zaman dizinini gösterir. Bu nedenle X ve W ifadeleri tam sayılardan oluşur.

$$S(t) = (X * W)(t) = \sum_{a=-\infty}^{\infty} X(a)W(t-a) \quad (3)$$

Makine öğrenmesi uygulamalarında giriş çok boyutlu bir dizi kümesinden oluşur. Konvolüsyon işleminde kullanılan çekirdek boyutları da dizi şeklindedir. Filtreler çok eksenlerde bir seferde konvolüsyon işlemini tamamlar. KSA girişi görüntüyü ifade eden iki boyutlu matris olduğundan kullanılan filtrelerde iki boyutludur.

$$S(i, j) = (I * K)(i, j) = \sum_m \sum_n I(i-m, j-n)K(m, n) \quad (4)$$

Şekil 2’de iki boyutlu konvolüsyon işleminde filtrenin görüntü üzerinde gerçekleştirdiği işlemi göstermektedir.



Şekil 2. a) 5×5 görüntü matrisi b) 3×3 filtre c) 3×3 sonuç matrisi

Makine öğrenmesinde konvolüsyon işlemi, seyrek gösterim, parametre paylaşımı ve kovaryans gösterimi olmak üzere üç temel fikir barındırır. KSA katmanları içerisinde her giriş birimi ile her çıkış birimi arasında farklı türde bir bağlantı içeren matris değişkenlerine sahiptir. Aynı zamanda KSA yapısı giriş görüntülerinin seyrek gösterimlerini elde edebilir. Kenar bilgilerinin daha belirgin bir şekilde elde edilebilmesi için işlem matrisi genişletilerek sıfır değeri eklenebilir. Bu işleme sıfır dolgu adı verilir.


Görüntüler içerisinde milyonlarca piksel barındırabilir. Fakat içerisinde anlamlı bilgiler içeren daha küçük boyutlara sahip özellikler bulunur. KSA modeli kullanılarak bu özelliklerin elde edilmesi görüntülerin daha anlamlı bir şekilde ifade edilmesini sağlar. Aynı zamanda daha az bir bellek kapasitesi gerektirir. Tahmin edilmesi planlanan hedef çıktısının hesaplanmasında daha az süreye ihtiyaç duyulur.

Parametre paylaşımı, bir modelde birden fazla işlev için aynı parametrenin kullanılmasını ifade eder. Geleneksel bir sinir ağında, ağırlıklı matristeki her eleman bir katmanın çıktısını hesaplamak için kullanılır. Bu nedenle bir ağırlıklarının birbiri ile bağlantısı olduğu söylenebilir. Çünkü bir girdiyeye uygulanan ağırlığın değeri, parametre paylaşımında olduğu gibi başka bir yerde uygulanan ağırlığın değerine bağlı olarak değişir. Konvolüsyon işlemi tarafından kullanılan parametre paylaşımı, her bir konu için ayrı bir parametre seti öğrenmek yerine, sadece bir setin öğrenileceği anlamına gelir.


KSA oluşturan katmanlar içerisinde aktivasyon fonksiyonları da yer alır. Şekil 3’de olduğu gibi KSA’nın temel yapısında konvolüsyon katmanı, havuzlama katmanı ve tam bağlı katmanlar bulunmaktadır. K×K boyutları filtre boyutlarını, H×G×D boyutları ise görüntü boyutlarını ifade eder.

$$\frac{H+2P-K}{S} + 1 \quad (5)$$


Havuzlama katmanı ile özellik haritalarındaki önemli özelliklerin seçimi gerçekleştirilir. Şekil 4’de bulunan maksimum havuzlama işlemi özellik haritasındaki 2×2 matrislerdeki maksimum değeri bir sonraki özellik matrisine aktarır. Sıklıkla tercih edilen havuzlama katmanları ortalama ve minimum havuzlama işlemi uygular.



Şekil 3. KSA Yapısına Bir Örnek



a) Maksimum Havuzlama



b) Ortalama Havuzlama

Şekil 4. a) Maksimum Havuzlama b) Ortalama Havuzlama

Havuzlama katmanı gerçekleştirdiği özellik seçim işlemi ile özellik matris boyutunu azaltarak parametre sayısını azaltır. Bu durum daha az bellek gereksinimi oluşturur. Havuzlama katmanı sonucunda oluşan özellik matrislerinin boyutu Denklem 6'daki gibi hesaplanır.

$$\frac{H + 2P - T}{S} + 1 \quad (6)$$

Rektifiye Edilmiş Doğrusal Birim (REDB) KSA yapısında yaygın bir şekilde kullanılan bir aktivasyon fonksiyonudur. $F(x) = \max(0, x)$ fonksiyonunu kullanarak işlem yapar. Sıfırdan küçük değerler REDB aktivasyon fonksiyonu ile sıfıra eşitlenir. Sıfırdan büyük değerler ise değerini korur.

Stokastik gradyan azalış optimizasyon algoritmasında REDB aktivasyon fonksiyonunun sigmoid ve tanh aktivasyon fonksiyonlarına kıyasla yakınsamayı önemli ölçüde hızlandırdığı tespit edilmiştir. Bu sonucun REDB fonksiyonunun doğrusal yapısından kaynaklandığı iddia edilmektedir. Yüksek işlem gerektiren tanh ve sigmoid ile karşılaştırıldığında REDB basit bir şekilde matristeki sıfırdan küçük elemanları sıfıra eşitleyebilir.

Tam bağlı katmanlarda belirli bir eşğin altındaki düğümlerin yok sayılması performansı arttırdığı gözlemlenmiştir. Bu işlem kaçınma katmanı ile gerçekleştirilir. Kaçınma değeri 1'den küçük bir değerdir. Bu değer KSA yapısının uygulandığı probleme ve veri kümesine göre farklılık gösterir. KSA yapısında bulunan bütün kaçınma katmanları için aynı kaçınma değerinin kullanılması gerekli değildir.

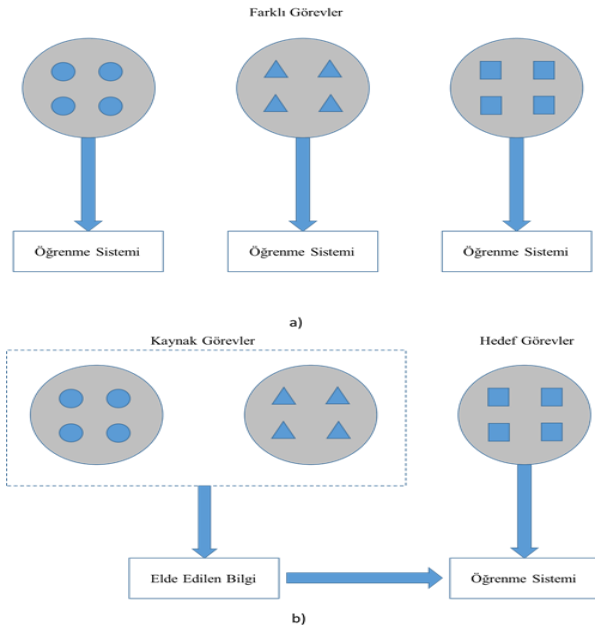
KSA yapısında bulunan Softmax bir sınıflandırıcı türüdür. Softmax, çok sınıflı bir lojistik regresyon analiz yöntemi olarak da değerlendirilebilir. Softmax içinde bulunan $1/\sum_j e^{\sigma_j}$ terimi veri dağılımını normalleştirir. Bu şekilde elde edilen değerlerin toplamı 1'e eşitlenir. Olasılık değerlerine bağlı olarak bir sınıflama işlemi gerçekleştirilir. Softmax'a giriş olarak verilen x verisindeki her değer için p ($y = j | x$) olasılığını tahmin etmesi istenir. Bu sayede her sınıf etiketi için farklı olasılık değerleri elde edilir.

Öğrenme işleminin sürdürülebilmesi için hata değerinin hesaplanması gerekir. KSA yapısındaki parametrelerin güncellenebilmesi için hata değeri Softmax kayıp fonksiyonu ile hesaplanmalıdır. Denklem 7'de Softmax kayıp fonksiyonu olarak ise çapraz entropi kayıp fonksiyonu kullanılmaktadır. L2 normu dediğimiz farklılıkların karesi, kayıp fonksiyonu olarak eğitim sırasında kullanılmıştır.

$$L_i = -\log\left(\frac{e^{f_{yi}}}{\sum_j e^{f_{ji}}}\right) \quad \text{veya} \quad L_i = -f_{y_i} + \log\left(\sum_j e^{f_{ji}}\right) \quad (7)$$

2.3. Transfer Öğrenmesi

Transfer öğrenmesi tekniği az sayıda veri bulunan problemlerin çözümü için kullanılmaktadır. Transfer öğrenmesi yöntemi, çok sayıda veri içeren farklı problemler için ön eğitilmiş KSA yapılarının parametreleri farklı problemler için başlangıç değeri olarak kullanılmasıdır. Çok veri ile eğitim gerçekleştirilen ön eğitilmiş KSA yapıları birçok problemin çözümünü genelleyecek yeteneğe sahiptir. Bu nedenle çalışma kapsamında araştırılan problem için kullanılacak veri sayısı yeterli olmadığından ön eğitilmiş KSA yapılarının parametreleri başlangıç değeri olarak kabul edilir. Sonrasında eğitim işlemi gerçekleştirilir. Şekil 5'te klasik makine öğrenmesi ve transfer öğrenmesi yöntemleri şematize edilmiştir.



Şekil 5. a) Klasik Makine Öğrenmesi b) Transfer Öğrenmesi

KSA tasarımından sonra ağ içerisindeki parametrelerin optimizasyonu gereklidir. Stokastik gradyan azalması ve adaptif momentyum algoritmaları sıklıkla tercih edilen optimizasyon algoritmalarıdır. Optimizasyon işlemi önemli parametrelerden biri de öğrenme oranıdır. Öğrenme oranı problemin çözümüne yakınsamak için kullanılan yaklaşma adımı olarak da ifade edilebilir. Öğrenme oranı büyük seçildiği takdirde KSA modeli, problemin çözümüne hızlı bir yakınsama gerçekleştirir. Yalnız öğrenme oranının büyük olması yakınsama hassasiyetini azaltır. Öğrenme oranının küçük olması durumunda ise KSA'nın problem çözümüne yakınsaması oldukça uzun süre alır. Diğer yandan ise ağı hassasiyeti artar. Bu nedenle öğrenme oranı ilk iterasyonlarda büyük

seçilirken sonraki iterasyonlarda kademeli olarak düşürülür. Adaptif bir öğrenme oranı ile hem daha kısa yakınsama süresi hem de yüksek yakınsama hassasiyeti elde edilmiş olur.

Çok derin yapıya sahip KSA'ların eğitimi için oldukça fazla miktarda etiketli veri gerekmektedir. Yüksek sayıda veri üretimi her problem için mümkün olmayabilir. Bu nedenler transfer öğrenimli ağların kullanımı tercih edilir. Transfer öğrenimli ağlar fazla miktarda veri ile çoklu sınıf için eğitim gerçekleştirilmiş KSA yapılarıdır. Bu ön eğitilmiş KSA yapıları diğer problemlerin çözümünü genelleyecek yeteneğe sahiptir. Uygun parametrelere sahip transfer öğrenimli KSA yapıları farklı problemlerin eğitim aşamasında başlangıç modeli olarak seçilir. Optimum parametrelere sahip bu yapılar yeni problemlerin çözümünü hızlı ve yüksek hassasiyetle yakınsatabilir. Aynı zamanda rastgele parametre dağılımı gösteren KSA yapıları ile yapılan eğitime göre daha az veriye ihtiyaç duyar.


2.5. K-En Yakın Komşu Algoritması

K-En Yakın Komşu (K-EYK) Algoritması veri içerisindeki benzerlikleri kullanarak sınıflandırma işlemi yapar. Veri içerisinde gerçekleştirilen gözlemler birbirine komşuluk teşkil eder. Birbirine benzer verilerin komşulukları fazla olup benzer olmayan verilerin komşulukları azdır. Veriler arasındaki uzaklık miktarına göre komşulukları azalır. K-EYK algoritmasında komşuluk sayısına göre benzer sınıflara atama işlemi gerçekleştirilir.

K-EYK algoritmasında tekrarlayan sınıf değeri yerine ağırlıklı komşu seçimi de kullanılabilir. Denklem 8 kullanılarak veriler arasındaki ağırlığın tersi veya tersinin karesi ağırlık değeri olarak atanır. Sonrasında güncellenen ağırlık değerlerine göre kategori veya sınıf seçimi gerçekleştirilir. x_i eğitim işleminde kullanılan verileri temsil ederken x_q test işleminde kullanılacak verileri gösterir. Denklem 8 belirtilen ağırlık değerleri güncellenerek veriler en yakın komşu haline getirmek mümkündür (Cover vd. 1967).

$$W = \frac{1}{d(x_q, x_i)^2} \quad (8)$$

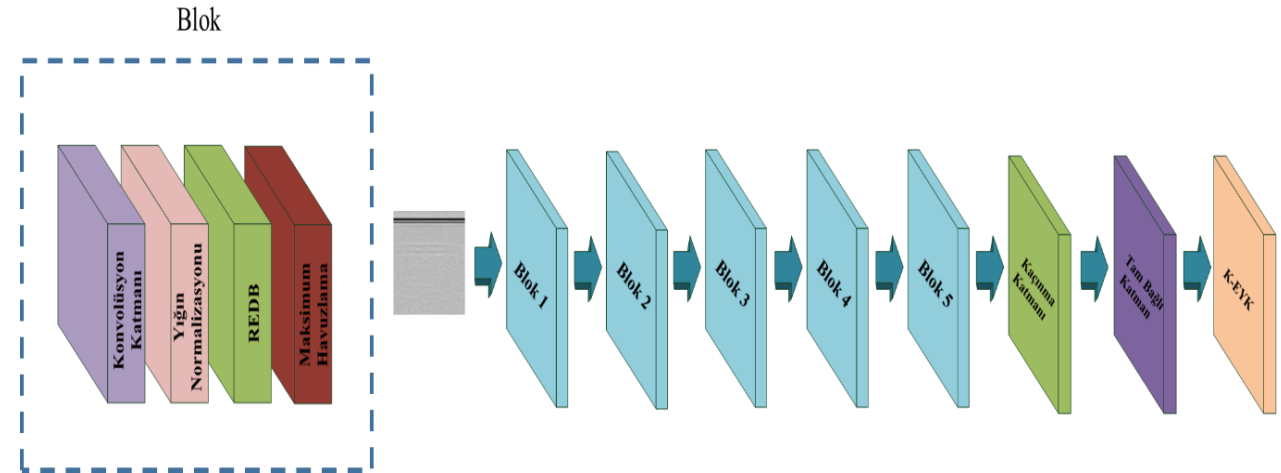
K-EYK algoritmasında n boyutlu özellik verilerini sınıflandırmak için en yakın komşu örneklerinden yararlanılır. Seçilecek k adet yakın komşu sayısının dikkate alınır. $k=1$ olması durumunda sınıflandırılmaya çalışılan veriler en yakın komşusu olduğu sınıfa atanır. Diğer bir deyişle k değişkeni kaç adet verinin sınıflandırmada dikkate alınacağını belirten sayıyı temsil eder (Cover ve Hart, 1967). Şekil 6'da $k=4$ değerine göre seçilen K-EYK algoritma sınıflaması bulunmaktadır.



Şekil 6. k=4 için K-EYK Algoritma Sınıflaması

2.6. Önerilen Yöntem

YNR B tarama görüntülerinin analizi için tasarlanan KSA yapısı mevcut veri sayısına göre



Şekil 7. Önerilen KSA Yapısı

Önerilen KSA yapısında bulunan Blok 1'de yer alan konvolüsyon katmanı 12 adet 3×3 boyutlarında filtreler içerir. Maksimum havuzlama katmanında ise havuzlama penceresi 3×3 boyutlarındadır. Blok 2, Blok 3 ve Blok 4'de yer alan konvolüsyon filtrelerin boyutları Blok 1'deki filtre boyutu ile aynıdır. Sadece filtre sayıları farklıdır. Blok 2'de 24 adet, Blok 3'de 36 adet ve Blok 4'de 48 adet konvolüsyon filtresi bulunmaktadır. Blok 5'de ise 3×3 boyutlarında 48 adet konvolüsyon filtresi bulunur. Maksimum havuzlama katmanındaki havuzlama penceresi 1×13 boyutlarındadır. Önerilen KSA yapısı karşılaştırmalı analizde kullanılan ön eğitilmiş ağırlara göre parametre sayısı oldukça azdır. Aynı zamanda yüksek bir performans göstermektedir.

3. BULGULAR

Önerilen KSA yapısı çerçevesinde 8505 adet YNR B tarama görüntüleri analiz edilmiştir. Karşılaştırmalı analiz kapsamında metrik olarak doğruluk, keskinlik, duyarlılık ve F-skoru seçilmiştir. Aynı zamanda önerilen KSA yapısının diğer ön eğitilmiş KSA yapıları ile birlikte karşılaştırmalı analizi gerçekleştirilmiştir. Ön eğitim KSA yapıları

oluşturulmuştur. Önerilen KSA yapısında farklı özelliklere sahip blok yapısı bulunmaktadır. Blok yapısında farklı filtre sayısı ve kayma miktarına sahip 1 adet konvolüsyon katmanı bulunmaktadır. Konvolüsyon katmanından elde edilen özellik haritalarına yığın normalizasyonu uygulanmaktadır. Bir sonraki katman ise REDB'dir. REDB katmanı, KSA yapısının doğrusallığını gidermek amacıyla kullanılır. En son olarak farklı pencere boyutu ve kayma miktarına sahip olan maksimum havuzlama katmanı ile özellik haritasının boyutları azaltılır. Önerilen KSA yapısında 5 adet blok yapısı bulunmaktadır. Sonrasında 1 adet kaçınma katmanı ve tam bağlı katman bulunur. En son olarak ise K-EYK katmanı yer alır. Önerilen yöntem Şekil 7'de önerilen yöntem şematize edilmiştir.

olarak AlexNet, GoogleNet, VGG-16, ResNet-50, Inception V2 ve DenseNet-121 tercih edilmiştir. Bütün eğitim işlemleri Matlab 2019 b programında 16 GB RAM ile 2,8 GHz'de Intel Core i7-7700 HQ işlemci üzerinde gerçekleştirilmiştir. Analiz kapsamında YNR B tarama verilerinin %75'i eğitim aşaması için, %25 ise test aşamasında kullanılmak üzere ayrılmıştır.

Bu çalışma YNR B tarama görüntü analizi için dört farklı metrik kullanılmıştır. Bu metrikler doğruluk, keskinlik, duyarlılık ve F1 skorudur (Ruuska vd. 2018).

$$\text{Doğruluk} = (TP + TN) / (TP + FN + TN + FP) \quad (9)$$

$$\text{Keskinlik} = TP / (TP + FP) \quad (10)$$

$$\text{Duyarlılık} = TP / (TP + FN) \quad (11)$$

$$\text{F1 Skoru} = (2 \times TP) / (2 \times TP + FN + FP) \quad (12)$$

TP, TN, FP ve FN değerleri sırasıyla doğru pozitif, doğru negatif, yanlış pozitif ve yanlış negatiflerin sayıdır.

Tablo 1. Karşılaştırmalı Sonuçlar

| KSA Modelleri | Metrikler (%) | YNR Çeşidi Tespiti | Tarama Frekansı Tespiti | Toprak Çeşidi Tespiti |
|-----------------|---------------|--------------------|-------------------------|-----------------------|
| AlexNet | Doğruluk | 95.89 | 90.88 | 84.39 |
| | Keskinlik | 96.12 | 90.89 | 84.20 |
| | Duyarlılık | 95.79 | 91.92 | 84.57 |
| | F1 Skoru | 95.95 | 91.40 | 84.39 |
| VGG-16 | Doğruluk | 96.84 | 94.54 | 93.00 |
| | Keskinlik | 96.97 | 94.73 | 92.49 |
| | Duyarlılık | 96.71 | 95.07 | 93.26 |
| | F1 Skoru | 96.84 | 94.90 | 92.87 |
| GoogleNet | Doğruluk | 96.36 | 94.08 | 90.54 |
| | Keskinlik | 96.61 | 94.29 | 89.14 |
| | Duyarlılık | 96.21 | 94.83 | 92.81 |
| | F1 Skoru | 94.41 | 94.56 | 90.94 |
| InceptionNet V2 | Doğruluk | 94.94 | 90.92 | 86.28 |
| | Keskinlik | 94.76 | 91.04 | 85.27 |
| | Duyarlılık | 94.61 | 91.90 | 88.46 |
| | F1 Skoru | 94.68 | 91.47 | 86.84 |
| ResNet-50 | Doğruluk | 96.21 | 92.58 | 81.46 |
| | Keskinlik | 96.07 | 92.70 | 80.36 |
| | Duyarlılık | 96.62 | 93.29 | 80.61 |
| | F1 Skoru | 96.35 | 92.99 | 80.48 |
| DenseNet-121 | Doğruluk | 95.26 | 94.5 | 91.36 |
| | Keskinlik | 95.05 | 94.52 | 90.46 |
| | Duyarlılık | 95.45 | 95.22 | 91.11 |
| | F1 Skoru | 95.25 | 94.87 | 90.78 |
| Önerilen Yöntem | Doğruluk | 97.16 | 94.88 | 90.63 |
| | Keskinlik | 97.31 | 95.02 | 90.50 |
| | Duyarlılık | 97.04 | 95.49 | 90.83 |
| | F1 Skoru | 97.18 | 95.24 | 90.66 |

Tablo 1’de önerilen yöntem ve ön eğitilmiş KSA yapıları için elde edilen doğruluk, keskinlik, duyarlılık ve F1 Skoru verilmiştir. YNR çeşidinin belirlenmesinde önerilen KSA yapısı %97.16 doğruluk, %97.31 keskinlik, %97.04 duyarlılık ve %97.18 F1 skoru ile en yüksek performansı göstermiştir. Çalışmada önerilen diğer ön eğitilmiş KSA yapılarına göre önerilen yöntemin gösterdiği performans daha yüksektir. Ön eğitilmiş KSA yapıları içerisinde VGG-16 modeli %96.84 doğruluk, %96.97 keskinlik, %96.71 duyarlılık ve %96.84 F1 skoru ile metrik değerleri ile en iyi performansa sahiptir. En düşük performans ise %95.89 doğruluk, %96.12 keskinlik, %95.79 duyarlılık ve %95.95 F1 skoru metrik değerleri ile AlexNet modeline aittir. YNR çeşidi tespitinde olduğu gibi önerilen KSA yapısı tarama frekansının tespitinde de en yüksek performansı elde etmiştir. Önerilen KSA yapısı ile elde edilen metrik değerleri %94.88 doğruluk, %95.02 keskinlik, %95.49 duyarlılık ve %95.24 F1 skoru şeklindedir. Tarama frekansı tespitinde VGG-16 modeli önerilen KSA modelinden sonra %94.54 doğruluk, %94.73 keskinlik, %95.07 duyarlılık ve %94.90 F1 skoru metrik değerleri ile en yüksek performansı göstermiştir. En düşük performans

AlexNet modeline ait olup %90.88 doğruluk, %90.89 keskinlik, %91.92 duyarlılık ve %91.40 F1 skoru metrik değerlerine sahiptir. Toprak çeşidinin tespitinde önerilen KSA yapısı VGG-16 ve DenseNet-121 modellerinden sonra en yüksek performansı elde etmiştir. Önerilen KSA yapısı ile elde edilen metrik değerleri %90.63 doğruluk, %90.50 keskinlik, %90.83 duyarlılık ve %90.66 F1 skoru şeklindedir. En yüksek performans gösteren VGG-16 modeli ise %93.00 doğruluk, %92.49 keskinlik, %93.26 duyarlılık ve %92.87 F1 skoru metrik değerlerine sahiptir. En düşük performans diğer görevlerde olduğu gibi %84.39 doğruluk, %84.20 keskinlik, %84.57 duyarlılık ve %84.39 F1 skoru metrik değerleri ile AlexNet modeline aittir.


4. SONUÇLAR ve TARTIŞMA

Bu çalışmada YNR B tarama görüntülerinin analizi için az parametreye sahip bir KSA modeli önerildi. YNR B tarama görüntülerinin elde edilmesinde kullanılan YNR cihaz çeşidi, tarama frekansı ve toprak çeşidini belirlemek amacıyla önerilen KSA yapısının yanı sıra ön eğitilmiş KSA yapıları da değerlendirilmiştir. Karşılaştırmalı analiz çerçevesinde önerilen KSA modeli YNR cihaz çeşidi ve tarama frekansının tespitinde en yüksek performansı göstermiştir. Toprak çeşidinin belirlenmesinde ise diğer ön eğitilmiş KSA yapılarına yakın performans sergilemiştir. Aynı zamanda diğer ön eğitilmiş KSA modellerine göre daha az bir parametre sayısı ile bu performans metrik değerlerini elde etmiştir. Gelecekte gerçekleştirilmesi planlanan çalışmalarda önerilen KSA modelinin performansının artırılması amacıyla concat yapıları ve uzun-kısa süreli bellek yapılarından yararlanılabilir.

KAYNAKÇA

- Benedetto A. ve Benedetto F. (2011). Remote Sensing of Soil Moisture Content by GPR Signal Processing in the Frequency Domain. *IEEE Sensors Journal*, 11 (10), 2432–2441.
- Cover T. M. ve Hart P. E., (1967). Nearest neighbor pattern classification. *IEEE Trans Inf Theory*. 13(1), 21–7.
- El-Mahallawy M. S. ve Hashim M. (2013). Material Classification of Underground Utilities From GPR Images Using DCT-Based SVM Approach. *IEEE Geoscience and Remote Sensing Letters*, 10 (6), 1542–1546.
- Frigui H., Ho K. C. ve Gader P. (2005). Real-time Landmine Detection with Ground-penetrating Radar Using Discriminative and Adaptive Hidden Markov Models. *EURASIP J. Adv. Signal Process*, 1867–1885.

- Gader P. D., Mystkowski M. ve Zhao Y. (2001). Landmine detection with ground penetrating radar using hidden Markov models. *IEEE Transactions on Geoscience and Remote Sensing*, 39 (6), 1231–1244.
- Gader P., Lee W. H. ve Wilson J. N. (2004). Detecting landmines with ground-penetrating radar using feature-based rules, order statistics, and adaptive whitening. *IEEE Transactions on Geoscience and Remote Sensing*, 42 (11), 2522–2534.
- Hinton G. E., (2007). Learning multiple layers of representation. *Trends Cogn. Sci.*, 11 (10), 428–434.
- Kovalenko V., Yarovoy A. G. ve Lighthart L. P. (2007). A Novel Clutter Suppression Algorithm for Landmine Detection With GPR. *IEEE Transactions on Geoscience and Remote Sensing*, 45 (11), 3740–3751.
- Krizhevsky A., Sutskever I. ve Hinton G. E. (2012). ImageNet Classification with Deep Convolutional Neural Networks. *Advances in Neural Information Processing Systems* 25, 1097–1105.
- Manandhar A., Torrione P. A., Collins L. M. ve Morton K. D. (2015). Multiple-Instance Hidden Markov Model for GPR-Based Landmine Detection. *IEEE Transactions on Geoscience and Remote Sensing*, 53 (4), 1737–1745.
- Öztürk, Ş., ve Akdemir, B. (2019). Cell-type based semantic segmentation of histopathological images using deep convolutional neural networks. *International Journal of Imaging Systems and Technology*, 29(3), 234-246.
- Öztürk, Ş., ve Akdemir, B. (2019). HIC-net: A deep convolutional neural network model for classification of histopathological breast images. *Computers & Electrical Engineering*, 76, 299-310.
- Pasolli E., Melgani F. ve Donelli M. (2009). Automatic Analysis of GPR Images: A Pattern-Recognition Approach. *IEEE Transactions on Geoscience and Remote Sensing*, 47 (7), 2206–2217.
- Ruuska S., Hämäläinen W., Kajava S., Mughal M., Matilainen P. ve Mononen J. (2018). Evaluation of the confusion matrix method in the validation of an automated system for measuring feeding behaviour of cattle. *Behavioural processes*. 148, 56-62.
- Shihab S. ve Al-Nuaimy W. (2005). Radius Estimation for Cylindrical Objects Detected by Ground Penetrating Radar. *Subsurf Sens Technol Appl.*, 6 (2), 151–166.
- Singh N. P. ve Nene M. J. (2013). Buried object detection and analysis of GPR images: Using neural network and curve fitting. *2013 Annual International Conference on Emerging Research Areas and 2013 International Conference on Microelectronics, Communications and Renewable Energy*, 1–6.



© Author(s) 2021. This work is distributed under <https://creativecommons.org/licenses/by-sa/4.0/>