





# Düzce Üniversitesi Bilim ve Teknoloji Dergisi

*Araştırma Makalesi*

## Düşey Elektrik Sondajı Verilerinin Genelleştirilmiş Regresyon Sinir Ağları ile Ters Çözümü

 Doğukan DURDAĞ<sup>a,\*</sup>,  Ertan PEKŞEN<sup>a</sup>

<sup>a</sup> Jeofizik Mühendisliği Bölümü, Mühendislik Fakültesi, Kocaeli Üniversitesi, Kocaeli, TÜRKİYE

\* Sorumlu yazarın e-posta adresi: dogukan.durdag@kocaeli.edu.tr

DOI: 10.29130/dubited.1100533

### ÖZ

Düşey elektrik sondajı (DES) verilerinin ters çözümü doğrusal olmayan bir problem olması nedeniyle zor bir işlemdir. Bu çalışmada, genelleştirilmiş regresyon sinir ağlarının özdirenç problemine uygulanabilirliği araştırılmıştır. Genelleştirilmiş regresyon sinir ağları (GRNN) ile düşey elektrik sondajı verilerinin ters çözümü test edilmiştir. Sinir ağı düz çözüm ile oluşturulan yapay verilerle eğitilmiştir. Ağ hem eğitim seti içinde bulunmayan diğer yapay veriler ile hem de arazi verisi ile test edilmiştir. Ayrıca GRNN parametresi olan yayılım parametresi de farklı değerler kullanılarak karşılaştırılmıştır. En düşük hata oranını veren yayılım parametresi kullanılmıştır. Yapay veriler 3 tabakalı modellerdir. Arazi verisi ise 4 tabakalı olarak değerlendirilmiştir. GRNN çıktısı yapay verilerde 3 tabakalı model için 3 özdirenç ve 2 tabaka kalınlığı olmak üzere 5 parametredir. Arazi verisinde ise 4 tabakalı bir model için 4 özdirenç ve 3 tabaka kalınlığı olmak üzere 7 parametredir. GRNN ile ters çözüm sonuçları çok düşük hata oranları ile başarılı olmuştur. DES verilerinin kalınlık ve özdirenç kestirimleri için GRNN yöntemi performansı yüksek bir oranda başarılı olmuştur.

**Anahtar Kelimeler:** *Yapay Sinir Ağları, Özdirenç, GRNN, DES*

## Inversion of Vertical Electrical Sounding Data by Using General Regression Neural Network

### ABSTRACT

The inversion of vertical electrical sounding (VES) data is a difficult task, since it is a non-linear problem. In this study, the general regression neural network approach was investigated to solve vertical electrical sounding inverse problems. The general regression neural network (GRNN) was tested to inversion of vertical electrical sounding data. The neural network was trained with synthetic data sets created by forward modeling. The network was tested both with another set of synthetic data and with field data. In addition, the spread parameter which is the GRNN parameter was compared using different values. The spread parameter giving the lowest error rate was used. Synthetic data are 3 layers models. Field data was inverted as 4 layers. The GRNN output is 5 parameters which are 3 resistivity and 2 layer thickness for the 3-layer model in synthetic data. In field data, there are 7 parameters which are 4 resistivity and 3 layer thickness for a 4-layer model. Inversion results of GRNN were successful with very low error rates. The GRNN method was successful with a high performance rate for estimation of the thickness and resistivity of VES data.

**Keywords:** *Artificial Neural Networks, Resistivity, GRNN, VES*

## I.GİRİŞ

Düşey elektrik sondajı (DES) ilk olarak Conrad Schlumberger tarafından 1900'lü yılların başlarında uygulanmıştır [1]. DES yöntemi hidrojeolojik, jeotermal, çevre ve mühendislik problemlerini çözmek için yaygın olarak kullanılır. Kosinski [2] akifer özelliklerini tahmin etmek için DES yöntemini kullanmıştır. Zohdy [3] birçok farklı örnekle DES verilerini değerlendirmiştir. Maiti [4] sismik aktivitelerin yüksek olduğu bir bölgede DES verilerini kullanarak yeraltının yapısını ortaya koymuştur. DES'in amacı derinlikle birlikte değişen tabakaların öz dirençlerini belirlemektir [1]. Tabakaların öz dirençlerini belirlemek için görünür öz direnç verilerinin ters çözümünün yapılması gerekir. DES ters çözümü, görünür öz direnç veri sayısı, parametre sayısından fazla olduğu için aşırı tanımlı ve doğrusal olmayan bir problemdir. Problemin doğrusal olmayan bir problem olmasından dolayı yeraltı parametrelerini yani tabakaların öz direnç ve kalınlık değerlerini belirlemek zor bir işlemdir. Bu problemin çözümü için farklı ters çözüm teknikleri ile çalışmalar yapılmıştır. Pekeris [5] DES verilerinin yorumlanması için uyguladığı doğrudan yorum yöntemi ilk uygulamalardan biridir. Daha sonrasında Argilo [6], Kunetz ve Rocroi [7] DES verilerinin yorumlanması için yapılmış sayısal hesaplamalar ve algoritmalar veren çalışmalardır. Ghosh [8] ise doğrudan yorumlama yöntemine doğrusal filtre teorisi katkısını yapmıştır. Inman [9] DES verilerine ridge regresyonunu ilk kez uygulamıştır. Johansen [10] ise kabaca ölçülen eğriyi verecek şekilde deneme-yanılma yöntemi ile en küçük kareler tabanlı bir sistem sunmuştur. Szaraniec [11] ise Pekeris'in [5] yaklaşımını iki nokta yöntemi ve çok katmanlı yöntem olarak adlandırdığı iki yeni yaklaşımla modifiye etmiştir. Chyba [12] en küçük kareler yöntemi ile DES verilerini değerlendirmiştir. Meju [13] ridge regresyonunu elektrik yöntemlerinden manyetotellürik (MT) ve geçici elektromanyetik (TEM) yöntemlerine uygulamıştır. Yapılan çalışmaların birçoğunda gözlenen veri ile hesaplanan veri arasındaki uyum genellikle yerel optimizasyon yöntemleri ile yapılmaktadır. Türev tabanlı parametre kestirimi uygulayan yerel optimizasyon yöntemlerinde çözüm başlangıç modelinin seçimine bağlıdır. Global optimizasyon yöntemlerinin başlangıç modeline ihtiyaç duymaması yerel optimizasyon yöntemlerine göre bir avantajdır. Yaygın olarak bilinen global optimizasyon yöntemlerinden bazıları Benzetimli Tavlama (SA), Genetik Algoritma (GA), Parçacık Sürü Optimizasyonu (PSO)'dur. DES verilerinin ters çözümü için global optimizasyon yöntemleriyle birçok çalışma yapılmıştır. Bhattacharya ve Sen [15] çok hızlı benzetimli tavlama yöntemini hem DES verilerine hem de İndüklenmiş Polarizasyon (IP) yöntemine uygulamıştır. Jha ve diğerleri [16] GA ile DES verilerinin ters çözümünü gerçekleştirmiştir. Martinez ve diğerleri [17] ise DES verilerinin ters çözümünü PSO yöntemi ile gerçekleştirmiştir. DES verilerinin ters çözümü için global optimizasyon yöntemlerinin başarılı sonuçlar verdiği ortaya koyulmuştur.

Yukarıda bahsedilen yöntemlerin dışında, biyolojik sinir ağlarından esinlenerek tasarlanmış olan Yapay Sinir Ağları (YSA) uzun yıllardır ilişkilendirme, sınıflandırma, genelleme, özellik belirleme ve optimizasyon amacıyla birçok farklı alanda kullanılan bir yöntemdir [18]. Bu yüzden YSA jeofizik problemlerin çözümünde de kullanılmaktadır. El-Kaliouby ve diğerleri [19] TEM verilerinin değerlendirilmesi için modüler sinir ağlarını uygulamışlardır. Calderon-Macias ve diğerleri [20] DES ve sismik verilerinin ters çözümü için ileri beslemeli yapay sinir ağlarını uygulamışlardır. Spichak ve Popova [21] MT verilerinin ters çözümü için yapay sinir ağları tabanlı bir çalışma yapmışlardır. Van der Baan ve Jutten [22] jeofizikte sinir ağları başlıklı çalışmada sinir ağlarının eğitim ve performanslarını sismik yöntem üzerinde göstermişlerdir. Poulton [23] hem sinir ağlarını detaylarıyla işlemekte hem de jeofizik veriler için nasıl kullanıldığını uygulamalarla göstermektedir. Burada YSA ile sismik verilerin dalga formu tanımlama, ilk varış belirleme, hız analizi, gürültü analizi, rezervuar karakterizasyonu gibi konulara değinmektedir. Bunun yanı sıra kuyu logları, gravite, manyetik, elektromanyetik, ve elektrik yöntemlerin de bazı konularını YSA açısından ele almıştır. Poulton [24] bu çalışmada ise kullanım açısından geri yayımlı çok katmanlı mimariler daha yaygın olmasına rağmen, jeofizik problemlerin çözümünde denetimsiz öğrenme için öz düzenleyici haritalar (SOM) veya olasılık tabanlı öğrenme için ise olasılıksal sinir ağları (PNN) gibi alternatif mimarileri daha önemli bulduğunu vurguluyor. Zhang ve diğerleri [25] kuyu içi elektrik verilerinin değerlendirilmesinde modüler sinir ağlarını uygulamışlardır. Bescoby ve diğerleri [26] arkeolojik alanda toplanmış manyetik verilerin değerlendirilmesi için çok katmanlı yapay sinir ağlarını

kullanmıştır. Al-Garni [27] ise manyetik verileri değerlendirirken modüler sinir ağlarını kullanmıştır. Modüler sinir ağları ayrıca El-Kalioubly ve Al-Garni [28] tarafından doğal potansiyel yönteminde uygulanmıştır. DES verilerinin ters çözümünde de YSA birçok çalışmada kullanılmıştır. El-Qady ve Ushijima [29] elektrik verilerinin ters çözümü için geri yayımlı bir sinir ağı kullandıkları çalışmada türev tabanlı yerel optimizasyon yöntemlerine göre sinir ağlarının daha hızlı sonuç verdiğini vurgulamışlardır. Srinivas ve diğerleri [29] ileri beslemeli geri yayımlı (FFBP) bir sinir ağının DES verilerinin ters çözümünde kullanılabilirliğini ortaya koymuştur. Maiti ve diğerleri [31],[32] farklı ortamlardan elde edilmiş arazi verilerini YSA ile değerlendirmiştir. Raj ve diğerleri [33] DES verilerinin ters çözümünde ileri beslemeli geri yayımlı bir sinir ağında Levenberg-Marquardt algoritması eğitiminin performansını açıkça ortaya koymuşlardır. Ayrıca performans kriteri olarak kökortalama kare hatasını (RMSE) kullanmışlardır.

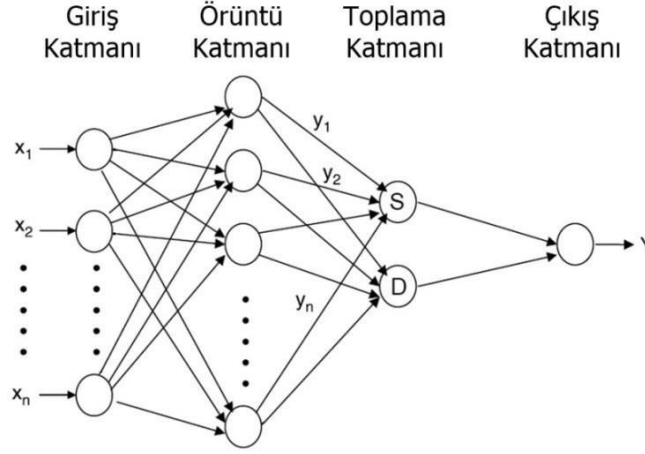
Yukarıda bahsedilen çeşitli çalışmalardan görüldüğü üzere birçok farklı YSA yapısı vardır. Genelleştirilmiş regresyon sinir ağları (GRNN), radyal tabanlı sinir ağlarının (RBNN) türlerinden biridir [23]. GRNN ilk olarak Specht [34],[35] tarafından ortaya atılmış ve geliştirilmiştir. Poulton [23] GRNN ağ yapısını, geri yayımlı çok katmanlı sinir ağları ile karşılaştırmıştır. Çok katmanlı sinir ağlarında eğitim aşamasında eşlenik gradyan, Levenberg-Marquardt, en dik iniş yöntemi gibi benzeri yöntemler kullanılmaktadır. Yapmış olduğu karşılaştırmada eğitim aşamasında yinelemeli yöntemlerle eğitim aşamasının yavaş olduğunu ortaya koymuştur. Kendi çalışmasında en iyi eğitim mimarisini açıkladığı kısımda 120000 yineleme sayısını kullandığını belirtmiştir. Ayrıca, Poulton [23] MATLAB'da GRNN'deki örüntü katmanındaki birimlerin sayısının eğitim setindeki birimlerin sayısına eşit olduğunu vurgulamıştır. Bu durumun GRNN ağ yapısını eğitim aşamasında verimli kıldığını belirtmiştir. Diğer taraftan geri yayımlı çok katmanlı sinir ağlarında, gizli katmandaki nöronsayısı, eşik değer fonksiyonu, öğrenme oranı, momentum, ağırlık başlatma gibi birçok parametre mevcuttur [23]. Bu parametrelerin her birinin optimum değerini bulmak için de ayrıca testler yapılması gereklidir. Bu durum jeofizikte ters çözüm amaçlı kullanılan bir yöntemi zaman açısından dezavantajlı duruma getirmektedir. GRNN ağ yapısı ise çok daha basittir ve sadece bir parametreye bağlıdır. Bu parametre yayılım ( $\sigma$ ) parametresidir.

GRNN yöntemi bazı jeofizik problemleri çözmek için kullanılmıştır. Ferahtia ve diğerleri [36] ile Djarfour ve diğerleri [37] sismik verilerden gürültülerin filtrelenmesi için GRNN yöntemini kullanmışlardır. Konate ve diğerleri [38] petrol sahası verilerinde gözenekliliği modellemek için GRNN yöntemini FFBP sinir ağları ile karşılaştırmıştır. Konate ve diğerlerinin [38], bulguları GRNN ağının yaygın olarak kullanılan FFBP ağından daha doğru ve güvenilir gözeneklilik parametre tahmini yapabildiğini kanıtlamıştır. Wiszniowski [39] Polonya'daki bir bakır bölgesinde indüklenen olayların yer hareketi tahmin denklemlerine GRNN yöntemini uygulamıştır. Ji ve diğerleri [40] yakın zamanda GRNN yöntemini yatay-düşey spektral orana (HVSZ) dayalı bir zemin sınıflandırmasında kullanmıştır. Garrouch [41] karmaşık dielektrik geçirgenlik ölçümlerinden rezervuar kayalarının katyon değişim kapasitesinin tahmin edilmesinde GRNN yöntemini kullanmıştır. Wiszniowski [42] GRNN yöntemini yer hareketi modellerinin tahmini için uygulamıştır. Zhou ve diğerleri [43] inşaat demiri çapını ve beton kalınlığını tahmin etmek için elektromanyetik indüksiyon veri seti tarafından eğitilmiş GRNN yöntemini uygulamıştır. Jeofizik problemlerinin çözümünde de kullanılan GRNN yönteminin, parametre kestirimini sağlayan ve doğrusal veya doğrusal olmayan problemler için yakınsayan bir yöntem olduğu kabul görmüştür.

Bu çalışmada yeraltındaki tabakaların öz direnç ve kalınlık parametrelerini kestirmek için DES verilerinin ters çözümü GRNN yöntemi kullanılarak yapılmıştır. Literatür araştırmamıza göre farklı YSA yapıları DES verileri için uygulanmış olmasına rağmen, GRNN yönteminin DES verilerine uygulanmadığı görülmektedir. Bu çalışmanın amacı GRNN yönteminin DES verilerine uyarlanabilir olup olmadığını araştırmaktır. Bulgularımıza göre, yöntemin kabul edilebilir hata oranında yeraltı parametrelerini kestirebilmek için kullanılabilirliğini göstermektedir.

## II. GENELLEŞTİRİLMİŞ REGRESYON SINIR AĞLARI

İnsan beyninden ilham alan YSA, birçok farklı alanda kullanılan oldukça popüler bir yöntemdir [44]. YSA'nın yaygın kullanımı, hem yöntemin gücünden hem de farklı türde problemlere uyarlanabilir olmasından kaynaklanabilir. GRNN, fonksiyon yaklaşımı, tahmin, modelleme ve eşleştirme için kullanılan bir RBNN türüdür. GRNN, diğer doğrusal olmayan sinir ağı tekniklerine göre birçok avantaja sahiptir. GRNN'nin avantajlarından biri, yinelemeli bir eğitim aşaması gerektirmemesidir. Başka bir deyişle, ağ giriş verilerinden doğrudan (tek geçişli öğrenme) öğrenir. Ayrıca, tahmin edilen model parametreleri, giriş verilerinin minimum ve maksimumları ile sınırlıdır. GRNN yöntemi, model parametrelerinin üst ve alt sayısal değerleri arasında doğrusal olmayan bir problemi çözebilir. Gözlenen verinin ters çözüm işleminde, bir eğitim veri seti oluşturmak için gözlem değerlerinin belirli bir oranda alt ve üst sınırlarını belirleyebiliriz. Ayrıca, yerel optimizasyon yöntemleri yerel minimuma karşılık gelen istenmeyen çözümlere yakınsamasına rağmen, GRNN yöntemi bu istenmeyen çözümlere yakınsamaz [35]. GRNN yönteminin genel yapısı Şekil 1'de gösterildiği gibi sırasıyla giriş katmanı, örüntü katmanı, toplama katmanı ve çıkış katmanı olarak adlandırılan dört katmandan oluşur. Her bir katman farklı sayıda nöronlardan oluşur ve katmanlar sırasıyla bir sonraki katman ile bağlantılıdır.



**Şekil 1.** GRNN'nin şematik gösterimi. GRNN yapısı sırasıyla giriş katmanı, örüntü katmanı, toplama katmanı ve çıkış katmanı olarak adlandırılan dört katmandan oluşur.

Gözlemleri içeren katman, giriş katmanı olarak bilinir. Giriş katmanındaki nöron sayısı verinin boyutuna eşittir. Örüntü katmanı ve toplama katmanı, gizli katman olarak da bilinir. Örüntü katmanındaki nöron sayısı eğitim setindeki veri sayısına eşittir. Bu katmanda bulunan nöronlarda eğitim verisi ile arazi verisi arasındaki uzaklıklar hesaplanır. Daha sonra bu uzaklıklar ve radyaltabanlı fonksiyon ile ağırlık değerleri hesaplanır. Örüntü katmanının verdiği bu ağırlık değerleri, toplama katmanındaki nöronlara iletilir. Toplama katmanında hem tüm ağırlık değerleri toplanır hem de örüntü katmanındaki her nörondan gelen ağırlık değerleri ile ilgili nörondaki eğitim verisinin çıkış değeri çarpılarak toplanır. Çıkış katmanında ise toplama katmanında hesaplanan çarpımların toplamı, ağırlıkların toplamına bölünür. Bu sayede çıkış katmanının verdiği değer ağ çıktılarını temsil eder. GRNN'nin çıktısı aşağıdaki şekilde hesaplanır [35].


$$Y = \frac{\sum_{i=1}^n y_i \exp(-D(x, x_i))}{\sum_{i=1}^n \exp(-D(x, x_i))} \quad (1)$$

Burada n sinir ağınnın giriş değerlerinin sayısıdır, D skaler bir fonksiyondur, x ve y değişkenlerdir [35].

$$D(x, x_i) = \sum_p \left( \frac{x_j - x_{ij}}{\sigma_j} \right)^2 \quad (2)$$

Burada  $p$  giriş vektörünün boyutunu gösterirken,  $\sigma$  yayılım (*spread*) parametresidir. Yayılım değeri eğer çok küçükse Gauss transfer fonksiyonu çok diktir. Bu durumda girişe en yakın olan örüntü birimi, daha uzak bir örüntü biriminden çok daha büyük bir çıktı üretir. Yayılım değeri eğer büyükse, eğim daha yumuşaktır ve birkaç örüntü birimi aynı giriş birimine karşılık gelebilir. Bu çalışmada yayılım parametresi deneme-yanılma yöntemi ile test edilmiştir.

Bu çalışmada Şekil 3'te gösterilen geliştirilmiş regresyon sinir ağı yapısı kullanılmıştır. Yapılan uygulamalar MATLAB yazılımı ile gerçekleştirilmiştir. MATLAB yazılımının *newgrnn* fonksiyonu kullanılmıştır. Ağ, Şekil 2'teki giriş ve çıkış dışında iki katmana sahiptir. Bu iki katmandan ilki bir radyal tabanlı transfer fonksiyonuna (*radbas*) sahiptir. Öklid uzaklığı ağırlık fonksiyonu (*dist*) ile ağırlıklı girdileri hesaplanırken net girdi fonksiyonu (*netprod*) ile katmanın net girdisi hesaplanır. Diğer katman ise bir doğrusal transfer fonksiyonuna (*purelin*) sahiptir. Normalize nokta çarpım ağırlık fonksiyonu (*normprod*) ağırlıklandırılmış bir girdiyi hesaplarırken toplam net giriş fonksiyonu (*netsum*) ise katmanın net girdisini hesaplar [45],[46].



**Şekil 2.** GRNN ağ yapısının gösterimi. Uygulamadaki yapay verilerin boyutundan dolayı giriş sayısı 19'dur, kestirilen parametrelerin boyutundan dolayı çıkış sayısı 5'dir. Eğitim verisinin boyutundan dolayı da radyal tabanlı katmanda boyut 1001'dir.

### III. DÜŞEY ELEKTRİK SONDAJI


DES yöntemi en düşük maliyetli jeofizik yöntemlerden birisidir. Yöntemde sabit bir noktanın her iki tarafına simetrik olarak iki akım ve iki potansiyel elektrot yerleştirilir (Şekil 3). Merkezi noktaya yakın olan potansiyel elektrotları sabit tutulurken, merkezi noktaya uzak konumda olan akım elektrotları birbirinden uzaklaştırılarak ölçüler alınır. Her bir ölçüm pozisyonunda voltaj farkı ölçülür ve görünür özdirenç hesaplanır [1].

$$\rho_a^0(s; b) = \frac{\pi s^2 - b^2}{2} \frac{\Delta V(s)}{b I} \quad (3)$$

Burada,  $s$  akım elektrotları ile orta nokta arasındaki uzaklık iken  $b$  potansiyel elektrotları ile orta nokta arasındaki uzaklıktır.  $\Delta V$  ise voltaj farkıdır. DES modelinde, yeraltının özdirençleri ( $\rho_i$ ) ve kalınlıkları ( $t_i$ ) ile temsil edilen yatay tabakalardan oluştuğu kabul edilir. Yeraltı  $2n-1$  boyutlu bir  $M$  vektör uzayına ait  $m=(\rho_1, t_1, \rho_2, t_2, \dots, \rho_{n-1}, t_{n-1})$  vektörü ile temsil edilir. Düz çözümde  $m$  parametrelerinin bilindiği varsayılır ve belirli yüzey konumuna karşılık gelen görünür özdirenç değerleri hesaplanır. Düz çözüm ile ilgili ifade Eş. 4'deki gibidir [1].

$$\rho_a^0(s; b) = \rho_1 + s^2 \int_0^\infty (T_1(\lambda, m) - \rho_1) \cdot J_1(\lambda s) \lambda d\lambda \quad (3)$$

Burada  $J_1$  birinci dereceden Bessel fonksiyonu,  $T_1$  ilk tabakanın dönüşük özdirenç ve  $\lambda$  uzaklığın tersi boyutunda integrasyon değişkenidir. Pekeris [5] bağıntıları, her katman için en alt tabakadan yüzeye doğru dönüşük özdirençlerin hesaplamasına olanak sağlar.



**Şekil 3.** Yeryüzünde akım ve potansiyel elektrotlarının dizilimini gösteren şematik. C1, C2 akım elektrotları iken P1, P2 elektrotları ise potansiyel elektrotlarıdır. Şematik ayrıca üç tabakalı yeraltı modelini de gösterilmektedir.

$$T_n(\lambda) = \rho_n \quad \text{ve} \quad T_i(\lambda) = \frac{T_{i+1} + \rho_i \cdot th(\lambda t_i)}{1 + \frac{T_{i+1} \cdot th(\lambda t_i)}{\rho_i}} \quad (4)$$

Burada  $T_i(\lambda)$  i. Tabakanın dönüştürük öz direncidir. Yüzeğe en yakın olan tabaka olan  $T_1$  hesaplanana kadar yinelemeli olarak hesaplama yukarı doğru ilerler. Son olarak Eş. 4'deki integrasyon doğrusal filtre teorisi aracılığıyla bir evrişim işlemi ile hesaplanır [8].

## IV. UYGULAMALAR

GRNN yöntemiyle hem yapay verilerle hem de arazi verisiyle DES verilerinin ters çözümü yapılmıştır. Düz çözüm için geliştirilen MATLAB kodu, Başokur [47] tarafından yazılmış diğer bir programlama dilinden çevrilmiştir. Düz çözüm yardımıyla hem gürültüsüz hem de %5 gürültü içeren yapay veriler üretilmiştir. Yapay verilerin oluşturulduğu model 3 tabakalıdır. Tablo 1'de model parametreleri ve hem gürültüsüz hem de %5 gürültülü yapay verinin GRNN yöntemi ile kestirilen sonuçları görülmektedir. Parametrelerin alt indisleri ait oldukları tabakanın numarasını göstermektedir.

**Tablo 1.** Model parametreleri ve GRNN yöntemi ile yapay veriler için kestirilen sonuçlar

Parametre	Model Parametreleri	GRNN Sonucu (Gürültüsüz)	GRNN Sonucu (%5 Gürültülü)
$\rho_1$ (ohm.m)	100	99.32	98.44
$t_1$ (m)	5	5.14	5.10
$\rho_2$ (ohm.m)	10	9.64	9.50
$t_2$ (m)	15	15.19	14.70
$\rho_3$ (ohm.m)	50	51.77	51.70
<b>RMSE</b> (%)		0.53	2.04

Yapay veriler 19 adet ölçüm değerine sahiptir. GRNN yönteminde kullanılmak üzere eğitim aşaması için 1001 adet veri düz çözüm aracılığıyla üretilmiştir. Giriş verisinin boyutu 19x1001'dir. Yapay


verilerdeki en düşük görünür özdirenç değeri 5 ohm.m iken en yüksek görünür özdirenç değeri 120 ohm.m'dir. Verilerin üretildiği parametrelerin boyutu ise  $5 \times 1001$ 'dir. GRNN yöntemi yapay verilerde çıktı olarak 3 özdirenç 2 kalınlık olmak üzere 5 parametreyi hesaplamaktadır. Yöntem ile farklı veriler için farklı sayıda tabaka parametrelerini kestirmek de mümkündür. Bu çalışmada yayılım parametresi deneme-yanılma yöntemi 0.1, 1, 5, 10, 50 değerleri ile yapılan testlerde optimum değer olarak belirlenen 1 değeri seçilmiştir. Belirlenen 1 değeri bu çalışma için optimum iken farklı yöntemlerde farklı yayılma değerleri optimum olabilir.

## A. GÜRÜLTÜSÜZ VERİ

Üç tabakalı yeraltı modeli ile üretilen gürültüsüz veri için test edilen farklı yayılma değerleri ile elde edilen sonuçlar Tablo 2'de verilmiştir. Kök ortalama kare hatasının en düşük olduğu sonucun yayılma değeri 1 değeridir.

**Tablo 2.** Gürültüsüz verinin test edildiği farklı yayılma değerleri ile elde edilen sonuçlar

Parametre	0.1 ( $\sigma$ )	1 ( $\sigma$ )	5 ( $\sigma$ )	10 ( $\sigma$ )	50 ( $\sigma$ )
$\rho_1$ (ohm.m)	99.68	99.32	99.93	98.05	98.64
$t_1$ (m)	4.97	5.14	4.92	5.13	5.53
$\rho_2$ (ohm.m)	11.14	9.64	11.30	9.79	13.38
$t_2$ (m)	15.15	15.19	15.04	14.70	15.40
$\rho_3$ (ohm.m)	46.17	51.77	45.54	49.21	61.31
<b>RMSE</b> (%)	0.66	0.53	0.71	0.86	5.86



**Şekil 4.** Gürültüsüz yapay veri ve GRNN sonucu 1 yayılma değeri ile kestirilen parametrelerle hesaplanan eğri. (RMSE = %0.53)

Üç tabakalı yer modeli için üretilen gürültüsüz veri ve GRNN ile ters çözüm sonuçları Şekil 4'te verilmiştir. Model parametreleri 3 tabakanın özdirenç değerleri ve yeryüzüne yakın olan ilk 2

tabakanın kalınlıklarıdır. Tabakaların özdirençleri sırasıyla, 99.32, 9.64 ve 51.77 olarak kestirilmiştir. İlk tabakanın kalınlığı 5.14 iken ikinci tabakanın kalınlığı 15.19 olarak kestirilmiştir. Kök ortalama kare hatası 0.53'dür.


## B. GÜRÜLTÜLÜ VERİ

Burada üç tabakalı yeraltı modeli için üretilen gürültüsüz veriye %5 oranında gürültü eklenmiştir. Gürültü içeren veri için test edilen farklı yayılma değerleri ile elde edilen sonuçlar Tablo 3'te verilmiştir. Kök ortalama kare hatasının en düşük olduğu sonucun yayılma değeri 1 değeridir.

**Tablo 3.** %5 Gürültülü verinin test edildiği farklı yayılma değerleri ile elde edilen sonuçlar

Parametre	0.1 ( $\sigma$ )	1 ( $\sigma$ )	5 ( $\sigma$ )	10 ( $\sigma$ )	50 ( $\sigma$ )
$\rho_1$ (ohm.m)	95.64	98.44	99.26	97.49	98.71
$t_1$ (m)	5.11	5.10	5.09	5.61	5.50
$\rho_2$ (ohm.m)	12.62	9.50	9.88	9.24	13.35
$t_2$ (m)	18.95	15.70	18.05	14.06	15.19
$\rho_3$ (ohm.m)	57.58	51.70	73.16	61.92	61.85
<b>RMSE</b> (%)	3.74	2.04	3.43	4.09	6.86

Gürültülü veri ve GRNN ile ters çözüm sonuçları Şekil 5'te verilmiştir. Model parametreleri 3 tabakanın özdirenç değerleri ve yeryüzüne yakın olan 2 tabakanın kalınlıklarıdır. Tabakaların özdirençleri sırasıyla, 98.44, 9.50 ve 51.70 olarak kestirilmiştir. İlk tabakanın kalınlığı 5.10 iken ikinci tabakanın kalınlığı 15.70 olarak kestirilmiştir. Kök ortalama kare hatası 2.04'tür.



**Şekil 5.** %5 Gürültülü yapay veri ve GRNN sonucu 1 yayılma değeri ile kestirilen parametrelerle hesaplanan eğri. (RMSE = %2.04)




### C. ARAZİ VERİSİ

GRNN ile ters çözümü yapılan arazi verisi Pekşen ve diğerleri [48] tarafından alınan T-8 konumundaki DES verisidir. Arazi verisi için test edilen farklı yayılma değerleri ile elde edilen sonuçlar Tablo 4'te verilmiştir. Kök ortalama kare hatasının en düşük olduğu sonucun yayılma değeri yapay verilerde olduğu gibi arazi verisi için de 1 değeridir.

*Tablo 4. Arazi verisinin test edildiği farklı yayılma değerleri ile elde edilen sonuçlar*

Parametre	0.1 ( $\sigma$ )	1 ( $\sigma$ )	5 ( $\sigma$ )	10 ( $\sigma$ )	50 ( $\sigma$ )
$\rho_1$ (ohm.m)	91.03	91.55	69.63	63.26	60.04
$t_1$ (m)	2.06	2.01	2.33	2.48	4.12
$\rho_2$ (ohm.m)	10.26	10.62	10.54	10.50	10.49
$t_2$ (m)	90.10	41.23	54.45	61.43	55.64
$\rho_3$ (ohm.m)	2.42	6.74	5.29	5.30	4.48
$t_3$ (m)	54.27	171.81	119.47	116.80	109.78
$\rho_4$ (ohm.m)	176.24	109.77	119.60	108.85	105.60
<b>RMSE</b> (%)	0.68	0.50	0.74	0.87	6.36

Arazi verisi ve GRNN ile ters çözüm sonuçları Şekil 6'da verilmiştir. Eğri üzerinde 4 tabakalı bir çözüm üzerinde çalışılmıştır. Tabakaların özdirençleri sırasıyla, 91.55, 10.62, 6.74 ve 109.77 olarak kestirilmiştir. Tabakaların kalınlıkları ise sırasıyla, 2.01, 41.23 ve 171.81 olarak kestirilmiştir. Kök ortalama kare hatası 0.50'dir.



*Şekil 6. Arazi verisi ve GRNN sonucu 1 yayılma değeri ile kestirilen parametrelerle hesaplanan eğri. (RMSE = %0.50)*

## **V. SONUÇLAR**

Bu çalışmada DES verilerinin yorumlanması için yapılan ters çözüm işleminde, yeraltı tabakalarının parametrelerin belirlenmesi için GRNN yöntemi kullanılmıştır. GRNN yöntemini uygularken yerel optimizasyon yöntemlerinde olduğu gibi iyi bir başlangıç modeline ihtiyaç duyulmamıştır. Ayrıca, hem yerel optimizasyon yöntemlerinde hem de eğitim aşamasında yerel optimizasyon yöntemlerini kullanan sinir ağlarında olduğu gibi yinelemeli bir süreç gerekmemiştir. Yöntem 3 tabakalı yapay veriler üzerinde test edilmiştir. Ayrıca yöntem DES arazi verisinin ters çözümü için de uygulanmıştır. Arazi verisi 4 tabakalı olarak değerlendirilmiştir ancak GRNN yöntemiyle farklı DES verileri için farklı sayıda tabaka parametrelerini kestirmek de mümkündür. GRNN çıktısı yapay verilerde 3 tabakalı model için 3 öz direnç ve 2 tabaka kalınlığı olmak üzere 5 parametredir. Arazi verisinde ise 4 tabakalı bir model için 4 öz direnç ve 3 tabaka kalınlığı olmak üzere 7 parametredir. Test çalışmalarında ortaya çıkan parametre kestirim sonuçları gerçek model parametrelerine oldukça yakındır. Nitekim hata oranları gürültüsüz veri için %0.53, gürültülü veri için %2.04 ve arazi verisi için %0.5 olmak üzere çok düşüktür. Hata oranlarının düşük olması ve grafikler üzerindeki gözlenen veri ile hesaplanan veri arasındaki uyumun açıkça görülmesi GRNN yönteminin DES verileri üzerinde başarılı olduğunu göstermektedir. Ayrıca GRNN yönteminde farklı yayılım değerleri için testler yapılarak optimum yayılım değerini veren en küçük hata oranı belirlenmiştir. Bulgularımıza göre GRNN yöntemi DES verilerinin ters çözümü için hızlı ve performansı yüksek olan bir yöntemdir.

## **VI. KAYNAKLAR**

- [1] O. Koefoed, *Geosounding principles, 1. Resistivity sounding measurements*, 1st ed., Amsterdam, Netherlands: Elsevier, 1979.
- [2] W.K. Kosinski and E.K. William, "Goelectric soundings for predicting aquifer properties." *Groundwater*, vol. 19, no. 2, pp. 163-171, 1981.
- [3] A.A. Zohdy, "A new method for the automatic interpretation of Schlumberger and Wenner sounding curves." *Geophysics* vol. 54, no. 2, pp. 245-253, 1989.
- [4] S. Maiti, G. Gupta, V.C. Erram and R.K. Tiwari, "Inversion of Schlumberger resistivity sounding data from the critically dynamic Koyna region using the Hybrid Monte Carlo-based neural network approach." *Nonlinear Processes in Geophysics*, vol. 18, no. 2, pp. 179-192, 2011.
- [5] C.L. Pekeris, "Direct method of interpretation in resistivity prospecting." *Geophysics*, vol. 5, no. 1, pp. 31-42, 1940.
- [6] S.M. Argilo, "Two computer programs for the calculation of standard graphs for resistivity prospection." *Geophysical Prospecting*, vol. 15, pp. 71-91, 1967.
- [7] G. Kunetz and J.P. Rocroi. "Traitement Automatique des Sondages Electriques Automatic Processing of Electrical Soundings." *Geophysical Prospecting*, vol. 18, no. 2, pp. 157-198, 1970.
- [8] D.P. Ghosh, "The application of linear filter theory to the direct interpretation of geoelectrical resistivity sounding measurements." *Geophysical Prospecting*, vol. 19, no. 2, pp. 192-217, 1971.
- [9] J. R. Inman, "Resistivity inversion with ridge regression." *Geophysics*, vol. 40, no. 5, pp. 798-817, 1975.
- [10] H.K. Johansen, "A man/computer interpretation system for resistivity soundings over a horizontally stratified earth." *Geophysical Prospecting*, vol. 25, no.4, pp 667-691, 1977.

- [11] E. Szaraniec, "Direct resistivity interpretation by accumulation of layers." *Geophysical Prospecting*, vol. 28, no. 2, pp. 257-268, 1980.
- [12] J. Chyba, "On the interpretation of resistivity soundings by the least-squares method." *Geophysical Prospecting*, vol. 31, no. 5, pp. 795-799, 1983.
- [13] M.A. Meju, "An effective ridge regression procedure for resistivity data inversion." *Computers & Geosciences*, vol. 18, no. 2-3, pp. 99-118, 1992.
- [14] Y. Meheni, R. Guérin, Y. Benderitter and A. Tabbagh, "Subsurface DC resistivity mapping: approximate 1-D interpretation." *Journal of Applied Geophysics*, vol. 34, no. 4, pp. 255-269, 1996.
- [15] B.B. Bhattacharya and M.K. Sen, "Use of VFSA for resolution, sensitivity and uncertainty analysis in 1D DC resistivity and IP inversion." *Geophysical Prospecting*, vol. 51, no. 5, pp. 393-408, 2003.
- [16] M.K. Jha, S. Kumar and A. Chowdhury, "Vertical electrical sounding survey and resistivity inversion using genetic algorithm optimization technique." *Journal of Hydrology*, vol. 359, no. 1-2, pp. 71-87, 2008.
- [17] J.L.F. Martínez, E.G. Gonzalo, J.P.F. Álvarez, H.A. Kuzma and C.O.M. Pérez, "PSO: A powerful algorithm to solve geophysical inverse problems: Application to a 1D-DC resistivity case." *Journal of Applied Geophysics*, vol. 71, no. 1, pp. 13-25, 2010.
- [18] W.A. Sandham and D.J. Hamilton, "Inverse theory, artificial neural networks." in Gupta H.K. (eds) *Encyclopedia of Solid Earth Geophysics*. Encyclopedia of Earth Sciences Series. Springer, 2021, pp. 796-807.
- [19] H.M. El-Kaliouby, M.M. Poulton and E.A. El Diwany, "Inversion of coincident loop TEM data for layered polarizable ground using neural networks." *In SEG Technical Program Expanded Abstracts*, Society of Exploration Geophysicists, 1999, pp. 259-262.
- [20] C. Calderón-Macías, M.K. Sen and P.L. Stoffa, "Artificial neural networks for parameter estimation in geophysics." *Geophysical Prospecting*, vol. 48, no. 1, pp. 21-47, 2000.
- [21] V. Spichak and I. Popova, "Artificial neural network inversion of magnetotelluric data in terms of three-dimensional earth macroparameters." *Geophysical Journal International*, vol. 142, no.1, pp. 15-26, 2000.
- [22] M. Van der Baan and C. Jutten, "Neural networks in geophysical applications." *Geophysics*, vol. 65, no. 4, pp. 1032-1047, 2000.
- [23] M.M. Poulton, *Computational neural networks for geophysical data processing*. 1st ed., vol. 30, USA, Elsevier, 2001.
- [24] M.M. Poulton, "Neural networks as an intelligence amplification tool: A review of applications." *Geophysics*, vol. 67, no. 3, pp. 979-993, 2002.
- [25] L. Zhang, M.M. Poulton and T. Wang, "Borehole electrical resistivity modeling using neural networks." *Geophysics*, vol. 67, no. 6, pp. 1790-1797, 2002.
- [26] D.J. Bescoby, G.C. Cawley and P.N. Chroston, "Enhanced interpretation of magnetic survey data from archaeological sites using artificial neural networks." *Geophysics*, vol. 71, no. 5, pp. 45-53, 2006.

- [27] M.A. Al-Garni, "Interpretation of some magnetic bodies using neural networks inversion." *Arabian Journal of Geosciences*, vol. 2, no. 2, pp. 175-184, 2009.
- [28] H.M. El-Kaliouby and M.A Al-Garni, "Inversion of self-potential anomalies caused by 2D inclined sheets using neural networks." *Journal of Geophysics and Engineering*, vol. 6, no. 1, pp. 29-34, 2009.
- [29] G. El-Qady and K. Ushijima, "Inversion of DC resistivity data using neural networks." *Geophysical Prospecting*, vol. 49, no. 4, pp. 417-430, 2001.
- [30] Y. Srinivas, A.S Raj, D.H. Oliver, D. Muthuraj and N. Chandrasekar, "A robust behavior of Feed Forward Back propagation algorithm of Artificial Neural Networks in the application of vertical electrical sounding data inversion." *Geoscience Frontiers*, vol. 3, no. 5, pp. 729-736, 2012.
- [31] S. Maiti, V.C. Erram, G. Gupta and R.K. Tiwari, "ANN based inversion of DC resistivity data for groundwater exploration in hard rock terrain of western Maharashtra (India)." *Journal of Hydrology*, vol. 464, pp. 294-308, 2012.
- [32] S. Maiti, G. Gupta, V.C. Erram and R.K. Tiwari, "Delineation of shallow resistivity structure around Malvan, Konkan region, Maharashtra by neural network inversion using vertical electrical sounding measurements." *Environmental Earth Sciences*, vol. 68 no. 3, pp. 779-794, 2013.
- [33] A.S. Raj, Y. Srinivas, D.H. Oliver and D. Muthuraj, "A novel and generalized approach in the inversion of geoelectrical resistivity data using Artificial Neural Networks (ANN)." *Journal of Earth System Science*, vol. 123, no. 2, pp. 395-411, 2014.
- [34] D.F. Specht, "Probabilistic neural networks." *Neural networks*, vol. 3, no. 1, pp. 109-118 1990.
- [35] D.F. Specht, "A general regression neural network." *IEEE transactions on neural networks*, vol. 2, no. 6, pp. 568-576, 1991.
- [36] J. Ferahtia, K. Baddari, N. Djarfour and A.K. Kassouri, "Incorporation of a non-linear image filtering technique for noise reduction in seismic data." *Pure and Applied Geophysics*, vol. 167, no. 11, pp. 1389-1404, 2010.
- [37] N. Djarfour, J. Ferahtia, F. Babaia, K. Baddari, E.A. Said and M. Farfour, "Seismic noise filtering based on generalized regression neural networks." *Computers & Geosciences*, vol. 69, pp. 1-9, 2014.
- [38] A.A. Konate, H. Pan, N. Khan and J.H. Yang, "Generalized regression and feed-forward back propagation neural networks in modelling porosity from geophysical well logs." *Journal of Petroleum Exploration and Production Technology*, vol. 5, no. 2, pp. 157-166, 2015.
- [39] J. Wiszniowski, "Applying the general regression neural network to ground motion prediction equations of induced events in the Legnica-Głogów copper district in Poland." *Acta Geophysica*, vol. 64, no. 6, pp. 2430-2448, 2016.
- [40] K. Ji, Y. Ren, R. Wen, C. Zhu, Y. Liu and B. Zhou, "HVSr-based Site Classification Approach Using General Regression Neural Network (GRNN): Case Study for China Strong Motion Stations." *Journal of Earthquake Engineering*, pp. 1-23, 2021.
- [41] A.A. Garrouch, "Predicting the cation exchange capacity of reservoir rocks from complex dielectric permittivity measurements." *Geophysics*, 83(1), MR1-MR14, 2018.

- [42] J. Wiszniowski, “Application of Focal Plane Directions for Estimating Ground Motion Models with General Regression Neural Networks.” *Pure and Applied Geophysics*, 1-11, 2022.
- [43] F. Zhou, Z. Chen, L. Ma, H. Liu, and G. Fang, “Applying machine learning for rapid and automatic characterizations of concrete rebars based on EMI and GPR data.” *In Geophysical Research Abstracts*, Vol. 21, 2019.
- [44] S. Haykin, *Neural Networks-A Comprehensive Foundation*, 3rd ed. New Jersey, USA: Pearson Education, Inc., 2009.
- [45] M.H. Beale, M.T. Hagan and H.B. Demuth, *Neural network toolbox. User’s Guide*, MathWorks, 2, 77-81, 2010.
- [46] P.D. Wasserman, *Advanced methods in neural computing*. John Wiley & Sons Inc., 1993.
- [47] A.T. Başokur, *Düşey elektrik sondajı verilerinin yorumu*. JFMO Eğitim Yayınları., 2010.
- [48] E. Pekşen, T. Yas and A. Kıyak, “1-D DC resistivity modeling and interpretation in anisotropic media using particle swarm optimization.” *Pure and Applied Geophysics*, vol. 171, no. 9, pp. 2371-2389, 2014.