

## Yapay Sinir Ağı Yöntemi ile Manyetotellürik Veride Sinyal ve Gürültü Ayırımı

### *Signal and Noise Detection in Magnetotelluric Data by the Artificial Neural Network Method*

**EBRU ŞENGÜL ULUOCAK<sup>1</sup>, EMİN U. ULUGERGERLİ<sup>2</sup>, HİLAL GÖKTAŞ<sup>3\*</sup>**

<sup>1</sup>Çanakkale Onsekiz Mart Üniversitesi Mühendislik Fakültesi Jeofizik Mühendisliği Bölümü Çanakkale

<sup>2</sup>Çanakkale Onsekiz Mart Üniversitesi Mühendislik Fakültesi Jeofizik Mühendisliği Bölümü Çanakkale

<sup>3</sup>Çanakkale Onsekiz Mart Üniversitesi Fen Edebiyat Fakültesi Fizik Bölümü Çanakkale

Geliş (received) : 05 Temmuz (July) 2012

Kabul (accepted) : 27 Mart (March) 2013

#### **ÖZ**

Bu çalışma kapsamında manyetotellürik yöntem verisindeki gürültü bileşenlerini sınıflamak için yapay sinir ağı yöntemi kullanılmıştır. Bu amaçla çok katmanlı, ileri beslemeli ve geri yayımlı bir model oluşturulmuştur. Seçilen eğitim setine bağlı olarak gürültülü zaman pencereleri % 89 doğrulukla belirlenmiştir. Ayrıca verideki gürültü türlerinin hepsi tanımlandığında (yapay veri), tüm gürültülü pencereler yapay sinir ağı yöntemi ile seçilip elenebilmektedir. Yapay veri ve arazi verisi ile yapılan uygulamalar sonucunda, hem görsel denetlemeye hem de geleneksel değerlendirme yöntemlerine göre, gürültülü veri pencerelerini sınıflayıp elemeye yapay sinir ağı yönteminin daha başarılı olduğu gösterilmiştir.

**Anahtar Kelimeler:** Manyetotellürik, Yapay Sinir Ağı, Zaman Serisi, Sinyal-Gürültü Tanıma

#### **ABSTRACT**

*In this study artificial neural network method was used to classify noisy components in the MT method data. For this purpose a multi-layered, feed-forward and back propagation model was employed. Noisy time windows were determined to an accuracy of 89 % depending on the training data set. In addition, when all types of noise in the data are defined (synthetic data), all noisy time windows can be selected and eliminated by artificial neural network method. Test results from synthetic and field data indicate that artificial neural network classification is successful in identifying and eliminating the noisy data windows compared to both visual inspection and conventional assessment methods.*

**Keywords:** Magnetotelluric, Artificial Neural Network, Time Series, Signal-Noise Detection

## GİRİŞ

Manyetotellürik (MT) yöntemde doğal elektromanyetik alanın birbirine dik elektrik ve manyetik bileşenleri zaman serileri biçiminde kaydedilir. Kaydedilen elektrik alanın birimi mV/km ve manyetik alanın birimi ise nT' dir. Bu bileşenler arasındaki doğrusal ilişki frekans ortamında;

$$X(\omega) = Z(\omega)Y(\omega) \quad (1)$$

olarak genellenebilir. Eşitlik (1)'de X; doğal elektromanyetik alanın yatay elektrik alan bileşenlerini ( $E_x$ ,  $E_y$ ) veya manyetik alanın düşey bileşenini ( $H_z$ ), Y ise yatay manyetik alan bileşenlerini ( $H_x$ ,  $H_y$ ) göstermektedir. Ayrıca eşitlikte  $\omega$ ; açısal frekans (radian), X ve Y anılan değişkenlerin Fourier dönüşümleri ve Z; karmaşık elektromanyetik empedanstır. Genellikle empedanstaki değişim görünür öz direnç ( $\rho_{ij}$ ) ve empedans fazı ( $\phi_{ij}$ ) ile incelenmektedir (basitlik için aşağıdaki deklemlerde  $\omega$  yazılmamıştır):

$$P_{xy} \approx 0.2T |Z_{xy}|^2 \quad (2.a)$$

$$\phi_{xy} = \tan^{-1} \left[ \text{Im}(Z_{xy}) / \text{Re}(Z_{xy}) \right] \quad (2.b)$$

Burada T; saniye cinsinden dönemdir (periyodur) (Vozoff, 1991). MT yöntemde sinyal ve gürültü bileşenleri birlikte kaydedilmektedir.

$$X=ZY+ \varepsilon \quad (3)$$

burada  $\varepsilon$ ; karmaşık ve rastgele gürültü düzeylerini ifade eder. Eşitlik (3)'ün en küçük kareler yaklaşımı ile çözümünden empedans dizeyi Z (\*\*) karmaşık eşlenik olmak üzere);

$$Z=(Y^*Y)^{-1}(Y^*X) \quad (4)$$

elde edilir (Swift, 1967; Sims ve diğ. 1971).

MT verisinden en küçük kareler yöntemiyle empedans kestirimi Gauss–Markov istatistik modeline dayanmaktadır. Bu yaklaşıma göre manyetik alan bileşenlerindeki ilişkisiz gürültüden fazla etkilenmediği varsayılmaktadır. Uygulamada bu varsayım empedans kestiriminde hatalara (kaymalara) neden olmaktadır (örn. Egbert ve Booker, 1986; Chave ve Thomson, 1989; Smirnov, 2003; Chave ve Thomson, 2004). Bu nedenle özellikle manyetik bileşenlerdeki gürültüyü yok etmek için ölçü alanındaki yerel gürültülerden etkilenmeyen uzak bir bölgede- Vozoff (1991)'a göre yerel alandan birkaç yüz metreden birkaç km'ye kadar uzaklıkta- alınan kaydın (uzak istasyon) yerel istasyon kaydı ile birlikte en küçük kareler hesaplamalarında kullanılması yoluna gidilmiştir (Goubau ve diğ., 1978; Gamble ve diğ., 1979). Ancak yapılan araştırmalar uzak istasyon ile yerel alan kayıtlarında aynı bandlarda, gürültü olabileceğini göstermiştir (örn. Rittler ve diğ., 1998). Bu soruna çözüm olarak da elektrik ve manyetik bileşenlerdeki gürültü içeriğine bağlı olarak verinin ağırlıklandırılması temeline dayanan bir yaklaşımla (robust yöntemi) empedans kestirimi yapılmaya başlanmıştır (örn. Egbert ve Booker, 1986; Sutarno ve Vozoff, 1989; Smirnov, 2003). Günümüzde eğer uzak istasyon kaydı varsa, uzak istasyon ve ağırlıklandırma yöntemlerinin birlikte kullanımı empedansın hesaplanmasındaki en genel yaklaşımdır (örn. Larsen ve diğ., 1996). Empedansın anılan farklı yollarla elde edilmesine ilişkin ayrıntılı bilgi Jones ve diğ. (1989)'de verilmiştir.

Uzak istasyon verisinin bulunmaması ve/veya baskın gürültü içeriği gibi uygulamada karşılaşılan sorunlar nedeniyle, MT yöntemde sinyal-gürültü ayrımı bizce hala önemli bir sorundur. Bu konudaki yaklaşımlar genel olarak, verideki gürültüye duyarlı farklı ağırlıklandırma yöntemlerinin geliştirilmesi ile seçilen nitelik ve sınır değerlerine göre verinin sınıflanarak ön-elenmesi çalışmalarına odaklanmıştır (örn. Manoj ve Nagarajan, 2003; Weckmann ve diğ. 2005).

Bu çalışmada karasal MT verisinin zaman ve frekans ortamı niteliklerine dayanan bir gürültü tanımı yapılarak, yapay sinir ağı (YSA) yöntemi ile sinyal-gürültü ayrımına yönelik bir uygulama gerçekleştirilmiştir. Empedans kestirimi gü-

rültü sınıflaması ve tanımlaması sonucunda *temiz* olarak belirlenen güvenilir veri kullanılarak yapılmaktadır. Segmentin güvenilirliği ise YSA yönteminde kullanılan model tarafından belirlenmektedir.

İzleyen metinde anılan yöntem ile ilgili kuramsal bilgi verildikten sonra yapay ve gerçek veri üzerinde yapılan deneme sonuçları sunulacaktır. Uygulamada karşılaşılan sorun ve çözüm önerilerine ilgili bölümlerde değinilecektir.

### YAPAY SİNİR AĞI (YSA) YÖNTEMİ

Zurada (1992)'ye göre YSA fiziksel bir hücre sistemidir ve YSA yönteminde bilgi, elde edilebilir, saklanabilir ve sonra yeniden kullanılabilir. YSA'nın sağladığı en önemli yenilik; ilgilenilen probleme yönelik öğrenme becerisi geliştirilebilmesi ve çözüme ilişkin **karar verme-genelleme** yeteneklerinin kullanılabilmesidir. Bunun için ağı eğitilmesi gerekir. Farklı öğrenme algoritmaları kullanılarak modelin hatasını en küçük yapan değişkenlerin yinelemeli biçimde hesaplanması sürecine **eğitim** denir. YSA öğrendikten sonra, daha önce eğitimde kullanılmayan veri grubu giriş verisi olarak kullanılıp ağı karar vermesi istenir.

Macias ve diğ. (2000)'de de belirtildiği gibi öğrenme yeteneği ve farklı problemlere kolay uyarlanabilme özeliği ile YSA yöntemi, arama jeofiziğinin birçok probleminin çözümünde kullanılmaktadır. YSA yönteminin jeofizik problemlere uygulanması ilk olarak 1980'lerden itibaren başlamıştır (Rumelhart ve diğ., 1986). YSA'nın hızlı ve güvenilir sonuçlarından iki ve üç boyutlu MT ters çözüm çalışmalarında (Zhang ve Paulson, 1997; Spichak ve Popova, 2000; Spichak ve diğ., 2002), doğru akım öz direnç verilerinin ters çözüm çalışmalarında (El-Qady ve Ushijima, 2001), görüntü ve sinyal işleme ile desen tanıma uygulamalarında (Raiche, 1991; elektromanyetik yöntem için; Poulton ve diğ., 1992; GPR verilerinde; Al-Nuaimy ve diğ., 2000; Ehret, 2009), kuyu logu verilerinden litoloji sınırlarının sınıflanmasından formasyon özelliklerinin (porozite, tuzluluk, sıvı doygunluğu gibi) tahmin edilmesine kadar birçok kuyu logu probleminde (örn. Ardjmandpour ve diğ., 2011) yararlanılmıştır.

MT gürültü yok etme uygulamalarında ise

YSA'nın kullanımı oldukça sınırlıdır ve genellikle veri sınıflama ve desen tanıma çalışmaları kapsamında uygulanmaktadır (örn. Manoj ve Nagarajan, 2003).

Bahsedilen YSA uygulamalarında araştırmacılar, organik hücre sistemi temeline dayanan YSA yönteminin jeofizik problemlere uygulanabilirliğini göstermenin yanısıra, yöntemin elle yapılan sinyal sınıflama çalışmalarının tersine öznellikten uzak, otomasyona yönelik becerilerini de vurgulamaktadırlar. Ayrıca uygulamalar, YSA model değişkenlerinin seçiminde bir standart olmayıp, veriye ve probleme yönelik yaklaşımlar yapıldığı göstermektedir.

### YSA Modeli

YSA'nın tarihsel gelişimi içinde birçok model geliştirilmiştir (örn. van der Baan ve Jutten, 2000 ve kaynakları). Bu çalışmada kullanılan YSA modeline ilişkin temel bilgiler verilecektir.

YSA modelleri genel olarak;

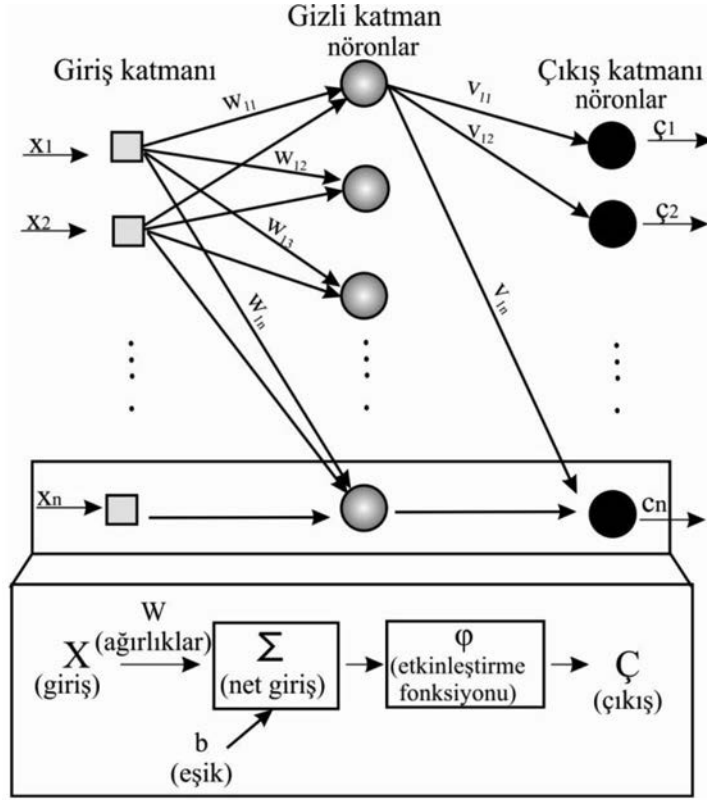
1. Ağ topolojisine (kaç katman, kaç nöron)
2. Bağlantı biçimine (katmanlar arası ve sinirler arası bağlantı vb.)
3. Öğrenme yöntemine (*danışmalı-danışmasız öğrenme vb.*)

bağlı olarak değişmektedir. Doğrusal olmayan problemlerin çözümünde çok katmanlı ileri beslemeli ağlar en çok tercih edilen YSA modelleridir. Ayrıca bu YSA modellerinin uygulama kolaylığı ve probleme kolay uyarlanabilmesi uygulanabilirliğini arttırmaktadır (Şahin, 2005). Bu tür ağlarda veri akışı girişten çıkışa doğru tek yönlüdür ve aynı katmandaki nöronlar arası bağ bulunmamaktadır (Şekil 1).

Şekil 1'de sunulan modele göre; X; giriş verisi, W; ağırlık değerleri, k; katman (tabaka) sayısı, i; nöron sayısı ve b; eşik (veya sapma) değeri olmak üzere net giriş T;

$$T_i^k = \sum_{j=1}^{n_k} (x_j w_{ji}) + b_i \quad (5)$$

dir. T net girişi,  $\phi$ ; etkinleştirme fonksiyonunun serbest değişkenidir ve  $\phi$  çıkışı;



Şekil 1. Bir gizli katmandan oluşan ileri beslemeli ağ mimarisi.  
Figure 1. Feed-forward network topology consisting of one hidden layer.

$$\zeta_i^k = \varphi(T_i^k) \quad (6)$$

olarak ifade edilir. Eşik değeri giriş verisinden bağımsız olarak etkinleştirme fonksiyonunun konumunu kaydırmak için sabit bir sayı olarak toplam değere eklenir. YSA modellerinde sadece 0 ve 1 veya -1 ve 1 çıkışlarını üreten, doğrusal ve doğrusal olmayan fonksiyonlar gibi farklı etkinleştirme fonksiyonları kullanılmaktadır (örn. van der Baan ve Jutten, 2000'de Şekil 1d). Eğrisel etkinleştirme fonksiyonları, öğrenen modellerde en çok kullanılan fonksiyonlardır (örn. Haykin, 1999; van der Baan ve Jutten, 2000; Kaftan ve diğ., 2011). Ayrıca aynı model içindeki farklı katmanlarda aynı fonksiyonun kullanılması zorunluluğu olmayıp, farklı fonksiyonların birlikte kullanımı da mümkündür.

YSA işlem akışında sonraki aşama ağı eğitilmesi ile ağ değişkenlerinin güncellenmesidir. Bu tür

ağ modellerinde genellikle danişmalı öğrenme algoritması olan geri yayılım algoritması kullanılmakta ve bu ağlara *geriye yayılım ağları* da denmektedir. Ayrıca özellikle sınıflama problemlerinde van der Baan ve Jutten (2000)'de de vurgulandığı gibi çoğunlukla öğretmenli (denetlemeli) YSA modelleri kullanılmaktadır. Bu yöntemde değişkenler genel olarak hatanın çıkıştan girişe doğru dağıtılması biçiminde güncellenir. Bu nedenle türevlenebilir bir etkinleştirme fonksiyonu seçilmelidir. Örnekler ve beklenen çıkışlar (hedef) verilerek eğitilen ağ (öğretmenli öğrenme işlemi), bu örneklerden yola çıkarak bir genelleme yapabilmektedir.

Eğitim için özetle;  $i$ . nöron için hesaplanan;  $h_i$  hedef ve  $\zeta_i$  çıkış değerleri arasındaki toplam karesel hatanın ( $E$ ) geriye yayılması;  $E_i$ 'nin en küçük değerini aldığı noktanın yinelemeli olarak bulunabilmesine dayanmaktadır.  $W_{ij}$ ;  $i$ . ve  $j$ . nöronların bağlantısının ağırlık değeri (Karnin, 1990);

$$\Delta W = -\eta \frac{\partial E_r}{\partial W_{ij}^k} \quad (7)$$

$\eta$ ; öğrenme oranını ifade etmektedir. Öğrenme hızı öğrenme oranına (ağırlıkların değişiminde adım büyüklüğüne) bağlı olarak değişir. Bu oranın belirlenmesinde ise bir kural olmayıp, küçük öğrenme oranı için hatanın en küçük değerinin bulunması fazla zaman alırken, çok büyük değerlerde tehlikeli biçimde iraksama oluşabilmektedir. Bu değer genellikle pozitif ve  $[0, 2]$  aralığında bir sayı seçilmektedir (van der Baan ve Jutten, 2000).

Türev zincir kuralı ile çözüldüğünde;

$$\Delta W = -\eta \frac{\partial E_r}{\partial C_i^{k+1}} \frac{\partial C_i^{k+1}}{\partial T(\text{net})_i^{k+1}} \frac{\partial T(\text{net})_i^{k+1}}{\partial W_{ij}^k} = -\eta (h_i - C_i^{k+1}) \frac{d\vartheta(T(\text{net})_i^{k+1})}{dT(\text{net})_i^{k+1}} \frac{\partial}{\partial W_{ij}^k} (\sum W_{ij}^k C_i^k) \quad (8.a)$$

$$\Delta W = -\eta (h_i - C_i^{k+1}) \vartheta'(T(\text{net})_i^{k+1}) C_i^k \quad (8.b)$$

elde edilir (Efe ve Kaynak, 2000). Burada  $E_{ri} \vartheta'(\text{net}) = \delta_i^{k+1}$  ifadesi;  $(k+1)$ . katmandaki hata için  $(k+1)$ . katman çıkış katmanı ise,  $k$ . katman gizli katman olarak düşünülebilir). Her bir çıkış nöronundan gelen hatanın kullanılması ile ağırlıklardaki değişim;

$$\Delta W_{ij}^k = \eta \delta_i^{k+1} C_i^k \quad (9)$$

olur. Bu aşamada gizli katman ile çıkış katmanı arasında değişken güncelleme; a. yinelemede;

$$W_{ij}^k(a) = W_{ij}^{k+1}(a-1) + \Delta W_{ij}^k(a) \quad \text{ve}$$

$$b_i^k(a) = b_i^{k+1}(a-1) + \Delta b_i^k(a) \quad (10)$$

dır (örn. Efe ve Kaynak, 2000). Hatanın çıkıştan geriye doğru dağıtılması sırasında karşılaşılan türev değerlerindeki ani sıçramalar  $\mu$ ; momentum çarpanı ile düzeltilebilmektedir. Momentum

katsayısı ağın öğrenme sırasında yerel bir en küçük değere takılıp kalmasını engeller (Öztemel, 2003). Genellikle  $[0, 1]$  aralığında seçilen momentum katsayısı (örneğin Karnin, 1990 çalışması örnek 1'de  $\mu = 0.5$  ve Leung ve diğ., 2003'te  $\mu = 0.9$  gibi) bellek gereksinimini arttırırken, hata yüzeyindeki küçük değişimler süzgeçlenmiş olmaktadır. Momentumlu ağırlıklar ise;

$$W_{ij}^k(a) = \mu W_{ij}^{k+1}(a-1) - \Delta W_{ij}^k(a) \quad (11)$$

biçiminde elde edilir. Ağın eğitimi (değişkenlerin güncellenmesi) hatanın en küçük değerinde veya yakınsama oranı çok yavaşladığında durdurulmaktadır.

Giriş verisinin seçimi ağın eğitimi etkileyen önemli bir olgudur. Eğitim ve denetleme işlemi için tüm veri kümesini tanımlayacak en uygun örneklerin giriş verisi olarak belirlenmesi YSA'nın başarısını doğrudan etkilemektedir. Ayrıca giriş, çıkış ve ağırlıkların ölçeklenmesi farklı ortamlardan gelen verilerin aynı ölçekte birlikte değerlendirilmelerine olanak sağlayabilmektedir (Manoj ve Nagarajan, 2003; van der Baan ve Jutten, 2000).

YSA modellerinde gizli katmanların ve nöronların sayısına ilişkin bir kısıtlama olmayıp, genellikle deneme yanılma yoluyla, probleme yönelik en uygun topoloji belirlenmektedir. Uygulamada az sayıda seçilen nöronların ağın öğrenme yeteneğini olumsuz yönde etkilediği, nöronların sayısındaki aşırı artışın ise ağın ezberlemesine neden olduğu görülmüştür. Bu durum sadece o veri için doğru tahmin yapan modelin, bir sonraki veri için yetersiz kalmasına yol açmaktadır. van der Baan ve Jutten (2000), gizli katmandaki nöron sayısının eğitim veri sayısından büyük olması gerektiğini söylemişlerdir. Araştırmacılar ağın hata değişimine bakarak, deneme yanılma yoluyla küçük nöron sayısından başlanarak, en uygun sayıyı bulmayı önermişlerdir. Dahası bir gizli katmanlı modellerle, iki gizli katmandan oluşan modellerin benzer sonuçlar ürettiği uygulamalar bulunmaktadır (örn. van der Baan ve Jutten, 2000). Bu nedenle örneğin daha az karmaşık YSA modellerinde ağırlıkların optimizasyonu ve dolayısıyla eğitim daha kolaylıkla yapılabilmektedir.

### YSA Sınıflaması İçin MT Verisinde Gürültü Tanımı

MT verisinde YSA ile gürültü tanıma/sınıflama çalışması için, öncelikle eşit değerli alt zaman segmentlerine ayrılan kayıta segmentlerin zaman ve frekans ortamı niteliklerindeki saçılmalara, diğer bir ifadeyle anılan niteliklere göre segmentlerin durağanlığının bozulmasına neden olan olgulara bağlı olarak gürültü tanımı yapılmıştır. Bu olgular; güç yoğunluğu spektrumundaki saçılmalar, iğnecik gürültüsü ve zaman serisi genliklerindeki (sinyal dokusundaki) değişimler olarak ifade edilebilir.

1-MT zaman serisindeki farklı gürültü bileşenleri verinin öz ve çapraz güç spektrumunda saçılmaya ve dolayısıyla da empedansta hatalara neden olmaktadır (Goubau ve diğ., 1978). Bu nedenle tüm kaydın güç yoğunluğu spektrumunun durağanlığını bozan segmentlerin belirlenmesi ile güç yoğunluğu spektrumuna bağlı indeks oluşturulmuştur. Güç yoğunluğu spektrumu hesaplamaları spektrumun non-parametrik kesitirimi olan *periodogram* ile yapılmıştır. Bu yöntem de her bir segmentin Fourier dönüşümlerinin karesel genliklerinin ortalamaları, segment örnek sayısının toplamının karesi ile normalleştirilerek spektral ortalamalar elde edilir. (Proakis ve diğ., 1992). Herhangi bir  $f$  frekans değeri (veya  $[f_i, f_{i+n}]$  aralığı) için bir  $X$  bileşeninin,  $i$ ; segment numarası,  $S_{iGYS}^f$ ;  $i$ . segmentin güç yoğunluğu spektrumu ve  $K_{GYS}^f$ ; bütün kaydın güç yoğunluğu spektrumunu göstermek üzere, segmentin güç yoğunluğu spektrumundaki saçılım 0/1 (gürültü/gürültüsüz) olarak işaretlenmiştir (eşitlik (12)).

$$\text{Indeks}_{GYS} = \begin{cases} 1, & S_{iGYS}^f \geq \text{medyan}(K_{GYS}^f) \pm \text{std}_{\text{medyan}} \\ 0, & S_{iGYS}^f < \text{medyan}(K_{GYS}^f) \pm \text{std}_{\text{medyan}} \end{cases} \quad (12)$$

Eşitlikte  $\text{std}_{\text{medyan}}$  medyandan sapmayı göstermektedir. Birinci gürültü indeksi 0 olan segmentler burada örneklendirilen MT verisinin  $E_y$  bileşeni, 3. frekans değeri için Şekil 2'de oklarla gösterilmiştir.

2-Diğer bir gürültü indeksi için zaman serisi dokusunu bozan iğnecikler ile zaman serisinin genliğindeki sapmalar belirlenmiştir.

iğnecik, doğrusal yönsemesi giderilmiş zaman segmentlerindeki mutlak genliğin kısa zaman aralıklarındaki ani artışlarıdır. Zaman serisindeki iğnecikler Mori ve diğ. (2007) tarafından düzenlenen, Akustik Doppler Velosimetri verisinin iğnecik gürültülerini yok etmek için tasarlanmış faz-uzay yöntemi ile belirlenmiştir. Bu yaklaşım 3 aşamalı olarak verideki iğnecikleri tanımlamaktadır. Birinci aşamada serinin birinci ve ikinci türevleri hesaplanır. İkinci aşamada evrensel kesme değeri ile verinin maksimumları belirlenir (diğer bir ifadeyle türevlerin standart sapmaları hesaplanır). Üçüncü aşamada ise gürültüsüz veri faz-uzay veya Poincaré haritaları ile gruplanır (Goring ve Nikora, 2002). Segmentin iğnecik indeksinin 0 olması (gürültülü segment) için belirlenen iğneciklerin mutlak genliğinin, 'iğneciksiz segmentin mutlak genlik+standart sapma' değerinden büyük olması gerekmektedir (Şekil 3).

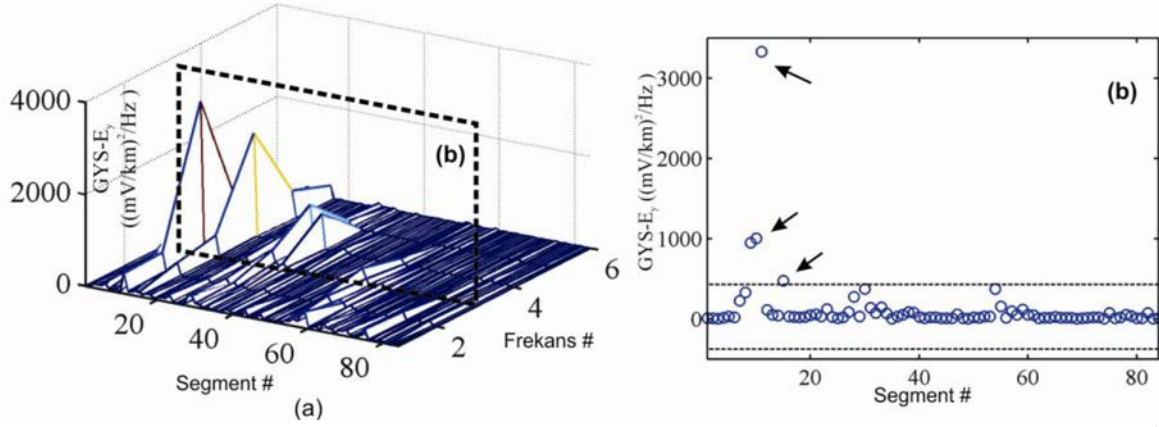
3- Son olarak iğnecik ve/veya daha uzun zaman aralıklı basamak türü gürültüler gibi zaman serisi dokusunu bozan değişimler, basit tanımlayıcı istatistik yaklaşımla, segmentin her bir değerinin, o segmentin ortalama genliğinden sapmasını hesaplayarak belirlenmiştir. Burada  $i$ ; segment numarası ve her bir segmentin genliğe göre standart sapmasının yüzde değişimi ( $\sigma_i$ ) olmak üzere,  $N$  segment sayısı için  $\sigma_i^N$  değerleri hesaplanmıştır.  $\sigma_i \geq \text{ort}(\sigma_i^N) + \text{std}(\sigma_i^N)$  koşulunu sağlayan segment 0; gürültülü olarak işaretlenmiştir.

Böylelikle incelenen frekans aralığında baskın gürültü sunan segmentler ile tek bir frekansta baskın bile olsa- zaman serisi genliğindeki ani değişimler ve zaman serisi dokusunu bozan iğnecik gibi etkiler her bir segment için gürültü olarak tanımlanmıştır.

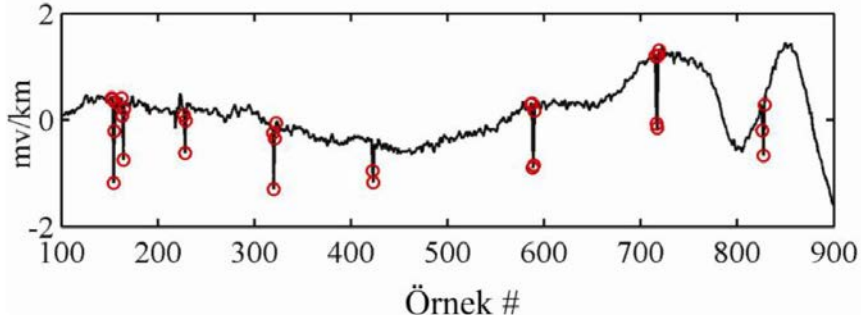
### UYGULAMA

Uygulamada kullanılan işlem basamakları özetle aşağıdaki gibidir:

1. Tüm kayıt zaman ortamında, her biri sabit değerli (512 veya 1024) alt segmentlere



Şekil 2 (a) Ey bileşeninin segment ve frekans sayısına bağlı güç yoğunluğu spektrumu (GYS) değişimi (b) 3. frekans için GYS değişimi (o orijinal veriyi, noktalı çizgi sınır değerlerini göstermektedir).  
 Figure 2 (a) Power spectral density (PSD) values of Ey component depending on segment and frequency numbers (b) PSD change for the 3rd frequency (circles indicate original data, dotted lines indicate limit values).



Şekil 3. Arazi verisi, Ey bileşenindeki iğnecik gürültüsü örneği.  
 Figure 3. Field MT data, spike noise in Ey component.

ayrılmış ve her segmentten doğrusal yönseme yok edilerek, 0 ortalamalı zaman serisi elde edilmiştir.

2. Daha sonra YSA eğitim verisinin her segmenti zaman serisi genliğine ve iğnecik gürültüsüne göre 0/1 olarak işaretlenmiştir.

3. Zaman serisi frekans dönüşümü öncesi zaman ortamında pencerelemiştir. Bu amaçla kullanılan *Hamming* fonksiyonu;  $a=0.5$  katsayısı,  $N$  veri boyu olmak üzere ( $0 \leq n \leq N/12$ )

$w(n)=a(1+(\cos(-\pi-\pi/n)))$  biçimindedir.  $x$ ; giriş verisi ve pencereleme işlemi  $y(n)=w(n)x(n)$ 'dir. Ardından ayrık Fourier dönüşümü (FD) ile her bir segmentin frekans bilgisi elde edilmiştir.

4. Frekans ortamındaki hesaplamalar -logaritmik artan aralıklar için- ortalama alınarak gerçekleştirilmiştir. Uygulanan ortalama alma işlemi zaman ortamı pencereleme ve örnekleme aralığına bağlı olarak tanımlanan ve kesme frekansı değerine göre seçilen frekans aralıkları için yapılmıştır (Simpson ve Bahr, 2005).

5. Bundan sonraki aşamada Vozoff (1991)'da belirtildiği gibi farklı MT bileşenlerinden öz ve çapraz güç yoğunluğu spektrumları hesaplanmıştır. Çapraz güç hesaplamalarında geleneksel yaklaşımla, elektrik alandan daha az gürültülü yatay manyetik alan bileşenleri kullanılmıştır.

6. Görünür öz direnç ve faz değerleri iki farklı yöntem kullanarak hesaplanmıştır. Öncelikle

MT değerlendirme çalışmalarında ilk yaklaşım olan en küçük kareler yöntemi ile (4) eşitliğinin çözümünden empedans hesaplanmıştır. İkinci yöntem olarak da ağırlıklandırma yöntemini uygulanmıştır. Empedansın anılan farklı yaklaşımlarla elde edilmesi bu makalenin kapsamı dışındadır. Ancak özetle ağırlıklandırma yönteminde Chave ve Thomson (2004)'te önerildiği gibi en küçük kareler kestirim hatasının bir ölçüsü olan verinin çoklu karesel uyumun gerçel değerleri başlangıç ağırlıkları olarak kullanılmıştır.  $X$  ve  $\bar{X}$ ; sırasıyla ölçülen ve kestirilen manyetik alan bileşenleri (benzer olarak  $Y$  ve  $\bar{Y}$  elektrik alan bileşenleri),  $^{**}$  karmaşık eşlenik,  $S_{XY}$ ; çapraz güç yoğunluğu spektrumu ( $S_{XX}$ ; öz güç yoğunluğu) olmak üzere çoklu uyum;

$$\gamma_{Y\bar{Y}} = \frac{|S_{YX}(S_{XX}^-)^{-1}S_{XY}^-|^2}{S_{YY}S_{XX}^*(S_{XX}^-)^{-1}S_{XX}(S_{XX}^-)^{-1}S_{XY}^-} \quad (13)$$

bagıntısı ile verilir (Chave ve Thomson, 2004). Ayrıca kestirim hatasını yok etmek için farklı ağırlık fonksiyonları birlikte kullanılarak (karma ağırlık fonksiyonu), yinelemeli olarak ağırlıklar güncellenmiştir. Bu yaklaşım ilişkin ayrıntılı bilgi Chave ve Thomson (2004)'da yer almaktadır.

7. YSA modeli için geri yayılım algoritması bir giriş katmanı, iki gizli katman ve bir çıkış katmanı olacak biçimde oluşturulmuştur. Ayrıca en uygun ağ topolojisi için denemeyanılma çalışmalarında en küçük katman ve nöron sayısı ile, en kısa eğitim süresinde en doğru tahmini yapacak ağırlık belirlenmesi hedeflenmiştir. Buna göre gizli katmanlardaki nöron sayıları sırasıyla 50 ve 15 olarak belirlenmiş ve bu katmanlarda *hiperbolik tanjant sigmoid* etkinleştirme fonksiyonu kullanılmıştır. Çıkış için ise, *logaritmik sigmoid* etkinleştirme fonksiyonu kullanılarak, 0 veya 1 çıkışı üreten bir nöronlu bir katman tasarlanmıştır. Momentum değişkeni 0.8, öğrenme oranı 0.2 olarak belirlenmiştir. Ağırlık, tüm kaydın en az yarısındaki gürültüyü tahmin etmesini beklediğimizden, eğitim verisi olarak empedans kestiriminde kullanılan dört bileşen verisinin sadece ikisi kullanılmıştır.

Bunun için aynı nitelikteki veri çifti seçilmiş,  $E_x$  ile eğitilen ağda  $E_y$  ve  $H_x$  ile eğitilen ağda ise  $H_y$  bileşenindeki gürültü tanımlanıp sınıflandırılmıştır.

8. Seçilen gürültü indeksine bağlı olarak YSA yöntemi ile yapılan sınıflama ve değerlendirme ile geleneksel MT empedans hesaplamasına ilişkin sonuçlar (yapay veri için; ağırlıklandırma yöntemi ve arazi verisi için; uzak istasyon+ağırlıklandırma yöntemi), aynı değişkenler aynı ölçekte olacak biçimde grafiklenerek sunulmuştur.

9. Veriye zaman veya frekans ortamında herhangi bir görsel düzeltme yapılmamıştır.

#### Örnek 1: Yapay Veri

YSA modelini denemek için ilk uygulama verisi olarak zaman ortamında  $[-1, 1]$  genlikli, rastgele değerlerden oluşan iki manyetik alan bileşeni ( $H_x$  ve  $H_y$ ) oluşturulmuştur. Kuramsal Z köşegen elemanları, Goubau ve diğ. (1978)'da da önerildiği gibi  $Z_{xy} \sim Z_{yx}$  olarak belirlenmiştir. Ayrıca bütün empedans bileşenleri birbirinden farklı ve frekanstan bağımsız seçilmiştir. Kuramsal değişkenlerden (1) doğrusal ilişkisi kullanılarak elektrik alan verisi oluşturulmuştur. Yapay veri örnekleme frekansı 20 Hz, bir segment için veri sayısı 1024 olarak tanımlanmıştır. Değişkenler 12 farklı frekans değeri için hesaplanmıştır. Gürültü yok etme uygulaması için manyetik alan (H) bileşenlerine farklı frekans ve zaman ölçeğinde, farklı genliklerde, iğnecik (örn. Ricker dalgacığı) ve dönemsel gürültü (sinüs fonksiyonu) eklenmiştir (Çizelge 1). Gürültü bileşenlerinin hangi segmentleri etkilediği Şekil 4'te sunulmuştur.

H bileşenleri incelendiğinde, verinin gürültülü segmentlerinin güç yoğunluğu spektrumunda genel yönelimden sapmaya neden olduğu Şekil 5a'da gözlenebilmektedir (okla belirtilen). Ayrıca Şekil 5b'de yatay eksen gerçel bileşen, düşey eksen ise sanal bileşen olmak üzere empedanstaki değişim Argand diyagramı biçiminde sunulmuştur. Şekilden de izlenebileceği gibi Argand diyagramında saçılım ve kümelenmeler gürültü etkisiyle oluşmuştur (örn. Weckmann ve diğ. 2005). Ek olarak Şekil 5c'de gürültü aynı frekans değeri için bazı segmentlerin uyum




Çizelge 1. Yapay veri için kullanılan gürültü türleri


Table 1. Noise types used for synthetic data

g-1:	Hx ve Hy bileşenleri ilişkili, [-1, 1] genlikli rastgele gürültü
g-2:	[-1, 1] genlikli, dönemsel gürültü; $f_1=0.48828$ Hz, $\sin(2\pi f_1 t)$
g-3:	İğnecik gürültüsü; $f_2=6.8945$ Hz, $3(1-2(\pi^2 f_2^2)(t-100dt)^2 e^{-(\pi^2 f_2^2)}(t-100dt)^2)$
g-4:	İğnecik ve dönemsel gürültü; $f_3=1.1328$ ve $f_4=2.4023$ Hz $3(1-2(\pi^2 f_3^2)(t-356dt)^2 e^{-(\pi^2 f_3^2)}(t-356dt)^2 + \sin(2\pi f_4 t))$
g-5:	Hx ve Hy bileşenleri ilişkili iğnecik gürültüsü; $H_y=H_x+n_3$

dt: örnekleme zamanı, t: zaman



(a)



(b)

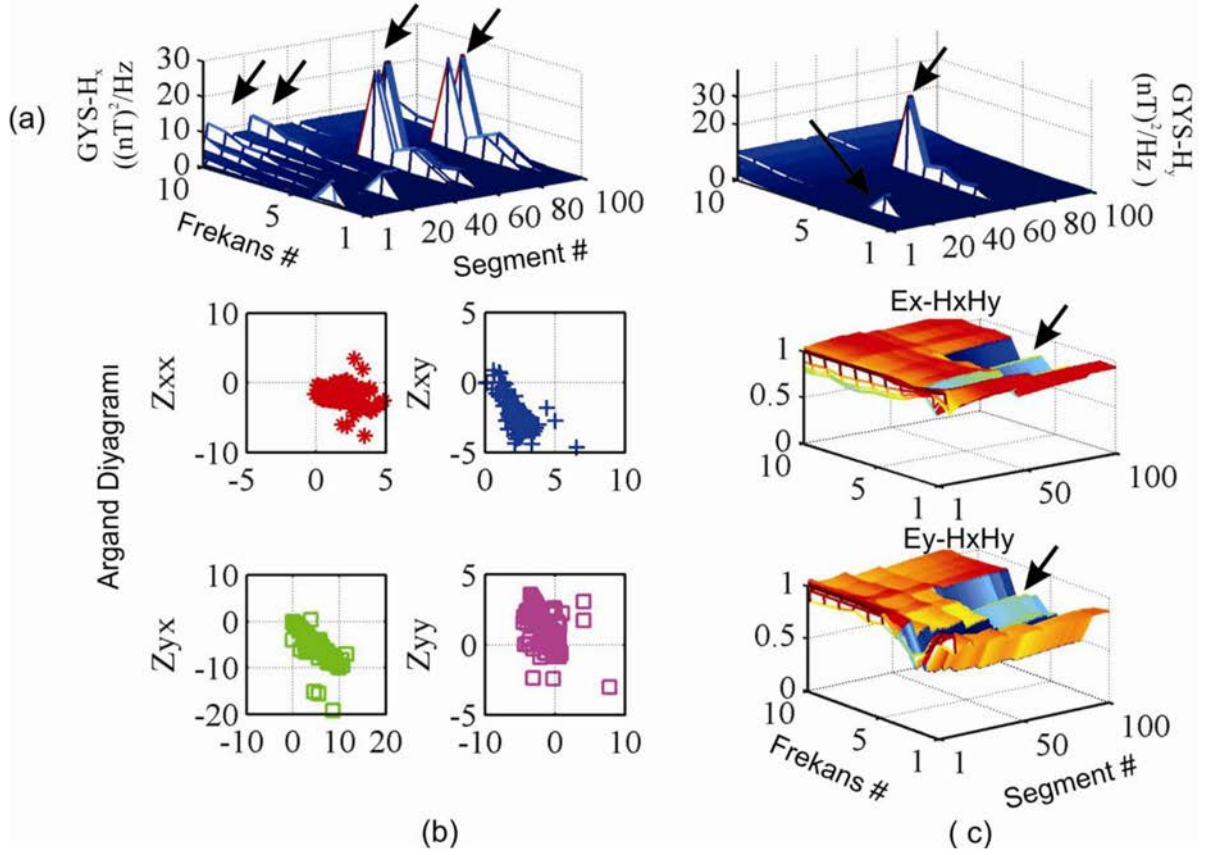
Şekil 4. Gürültü türleri ve gürültülü segment numaraları (a) Hx bileşeni (60, 61 ve 62. segmentlerde tüm gürültü türleri baskındır) (b) Hy bileşeni.

Figure 4. Noise types and noisy segments (a) Hx component (all noise types are active in the 60th, 61st, and 62nd segments) (b) Hy component.

değerlerinde ( $E_x-H_x H_y$  ve  $E_y-H_x H_y$ ) düşüş ve düzensizliğe neden olmuştur (okla işaret edilen).

H bileşenlerinin zaman serisi genlik değişimleri % olarak Şekil 6'da yer almaktadır. Sürekli çizgiler genlikteki sapmaların gürültü olarak tanımlanmasında kullanılan kabul aralığını ifade etmektedir.

YSA eğitimi için kullanılan  $H_x$  bileşeni Şekil 7a'da yer almaktadır. Şekil 7b ve c'de gürültülü segment örnekleri, Şekil 7d, e ve f'de ise gürültü türlerine göre sınıflamada kullanılan indeksler sunulmuştur. Üç gürültü türünden de etkilenen segmentler, yok edilmesi hedeflenen gürültülü veriyi tanımlamaktadır. Bu nedenle YSA



Şekil 5. Gürültülü yapay veri (a) H bileşenleri güç yoğunluğu spektrumları (GYS) (b) ağırlıklandırma yöntemi ile hesaplanan empedansın Argand diyagramı (c) Ex-HxHy ve Ey-HxHy uyumunun segment ve frekans sayısına bağlı değişimleri.

Figure 5. Noisy synthetic data (a) power spectral densities (PSD) of H components (b) Argand diagram of impedance calculated by robust method (c) changes in Ex-HxHy and Ey-HxHy coherence based on segment and frequency number.

modelinde gürültüsüz verinin hedef çıktısı olarak bu niteliklerin "1" olduğu segmentler dikkate alınmıştır (Şekil 8a kırmızı işaretlerle gösterilen YSA hedef sınıfları). Böylelikle üç gürültü türü için, gürültü seçiminde yapılan kabul kriterlerinin olumsuzluklarından etkilenmeden, verideki tüm gürültü tanımlanmış olmaktadır.


Hedef sınıflar kırmızı ve ağın ürettiği sonuçlar yeşil olmak üzere, eğitim sonucu Şekil 8a'da yer almaktadır. Ağın eğitimi basit bir dizüstü bilgisayarda (Intel Core 2 CPU, 2 GHz, 1.99 GB RAM), örneğin 73. segment için 2.7 s (Şekil 8b), tüm verinin eğitimi ise 65.8 s'de tamamlanmıştır. Şekil 8b'de kesikli çizgi, ağ değişkenleri güncellenirken ortalama karesel hatanın değişimini, diğer bir ifadeyle eğitimin durma zamanını ifade

etmektedir.

H<sub>x</sub> ile eğitilen ağa H<sub>y</sub> verisi giriş verisi olarak tanıtılıp, verideki gürültü 1.6 s'de %100 doğrulukla sınıflanmıştır (Şekil 9).

YSA sınıflaması ardından gürültülü segmentlerin elenmesiyle Şekil 5'te izlenen saçılımların yok edilebildiği gözlenmiştir (Şekil 10). Gürültüsüz veriden en küçük kareler yöntemi ile empedans değerleri hesaplanmış ve başlangıçta atanan kuramsal empedans değerlerine ulaşılmıştır

$\begin{bmatrix} 2+2i & 3+3i \\ 5+5i & -1-1i \end{bmatrix}$ , Şekil 10b). Ayrıca gürültülü veriden geleneksel yaklaşımla hesaplanan görünür özdirenç ve faz değerlerinde eğri yönelimi ve hata aralığı bakımından saçılımlar varken (Şekil 11a ve b, mavi ve kırmızı renklerle gös-



Şekil 6. Zaman serisi genliğindeki sapmaların segmentlere göre değişimi.  
Figure 6. Change of the amplitude of time series deviations as per segments.

terilen değişimler), gürültüsüz veriden en küçük kareler yöntemi ile elde edilen değerlerde bu hataların düzeldiği gözlenmiştir (Şekil 11).

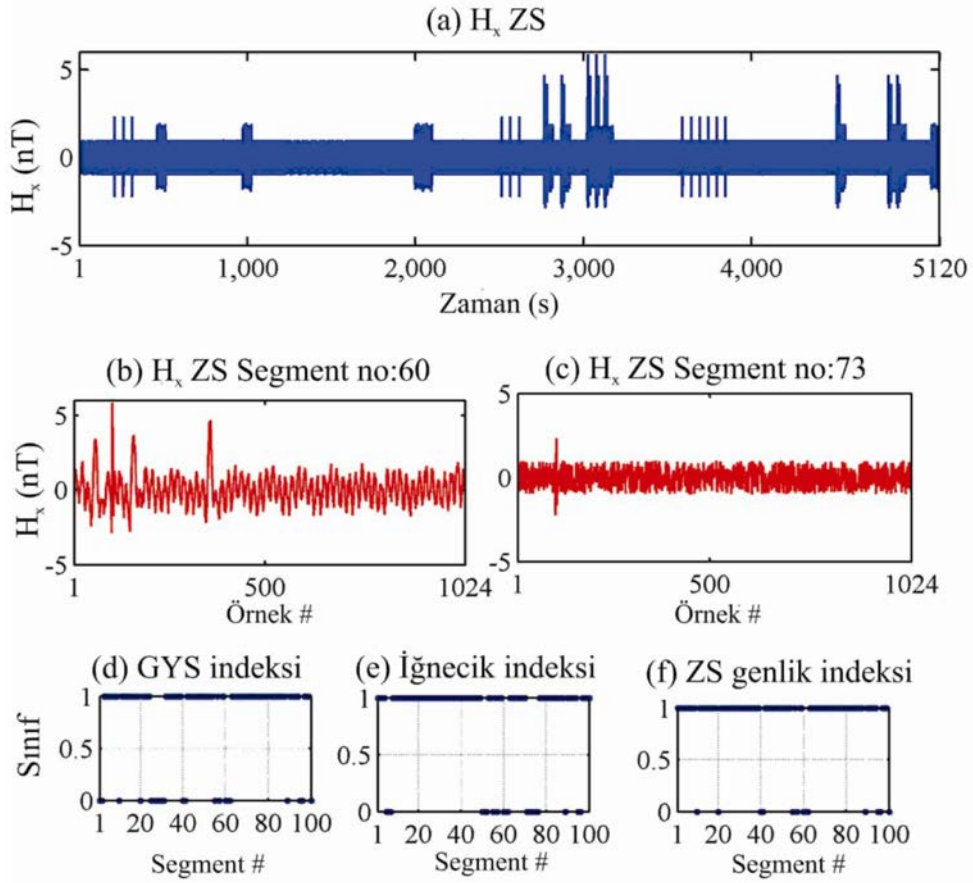
#### Örnek 2: Arazi Verisi

Örnek 2'de sunulan arazi verisi Kuzey Dogu Brezilya'da yürütülen yerel projen alınmıştır (Uluggerli ve diğ., 2011). Sao Joaquim do Pacui (SJP) istasyonu ile uzak istasyon verisi olarak da Tatuoca (TTA) istasyonu uzun dönemli MT kayıtları kullanılmıştır. Kayıt 1 Hz frekans örnekleme ve herbiri 1024 veri içeren 84 segmentten oluşmaktadır. Veri bileşenlerinin güç yoğunluğu spektrumlarındaki değişimler ve geleneksel gürültü yok etme yaklaşımı (uzak istasyon+ağırlıklandırma yöntemi) ile hesaplanan empedans bileşenlerinin segmentlere göre değişimleri -rastgele seçilen 5. frekans için- Şekil 12'de yer almaktadır. Gürültü, bazı frekanslar için E ve H bileşenleri arasında yüksek ilişki gösterir biçimde, segmentlerin spektrum değerlerinde sapmalara neden olmuştur (Şekil 12a). Ayrıca Şekil 12c'de gürültülü verinin uyum değerlerindeki değişim yer almaktadır. Okla işaret edilen sapmalar, izleyen bölümlerde açıklanan YSA gürültü yok etme uygulamasıyla düzeltilmiştir.

YSA eğitiminde kullanılan  $E_x$  ve  $H_x$  zaman serileri sırasıyla, Şekil 13a ve Şekil 14a'da yer almaktadır. Şekil 13a'da okla gösterilen zaman aralığındaki iğnecik gürültüsü, Şekil 13b'de ayrıntılı olarak gösterilmiştir. Şekil 14b'de ise  $H_x$  bileşeninin güç yoğunluğu spektrumundaki gürültü örneği bulunmaktadır. Her iki bileşenin YSA hedef sınıfları sırasıyla Şekil 13c ve Şekil 14c'de sunulmuştur.


YSA eğitimi sonucunda ağ tüm verideki gürültüyü bir kaç dakikada % 89 doğrulukla sınıflamıştır (Şekil 15). Sınıflanan gürültülü segmentlerin elenmesi ile hesaplanan güç yoğunluğu spektrumlarında Şekil 12a'daki sapmaların yok edildiği gözlenmektedir (Şekil 16a). Ayrıca gürültüsüz veriden en küçük kareler ile hesaplanan empedans, geleneksel yolla hesaplanan değerlere göre Argand diyagramında Şekil 12b'deki saçılımları göstermez (Şekil 16b). Dahası uyumdaki düzensiz değişimlerin Şekil 12c ile karşılaştırıldığında yok edildiği söylenebilir (Şekil 16c).

Gürültülü verinin en küçük kareler ile hesaplanan görünür özdirenç değerlerinde xy yönünde ve özellikle 3. frekansta eğrinin yöneliminde sapma (Şekil 17a), görünür özdirenç ve fazın yx




Şekil 7. Sentetik veri  $H_x$  bileşeni (a) zaman serisi (ZS) (b) [3020.8, 3072] s zaman aralığındaki 60. segment, tüm gürültü türleri (c) [3686.4, 3737.6] s zaman aralığındaki 73. segment, iğnecik gürültüsü (d) güç yoğunluğu spektrumuna (GYS) bağlı indeks (e) iğnecik indeksi ve (f) zaman serisi genlik değişimlerine bağlı gürültü indeksi.

Figure 7. Synthetic data  $H_x$  component (a) time series (TS) (b) 60th segment in [3020.8, 3072] s time frame, all noise types (c) 73rd segment in [3686.4, 3737.6] s time frame, spike noise, index of (d) power spectral density (e) spike and (f) the amplitude of TS.

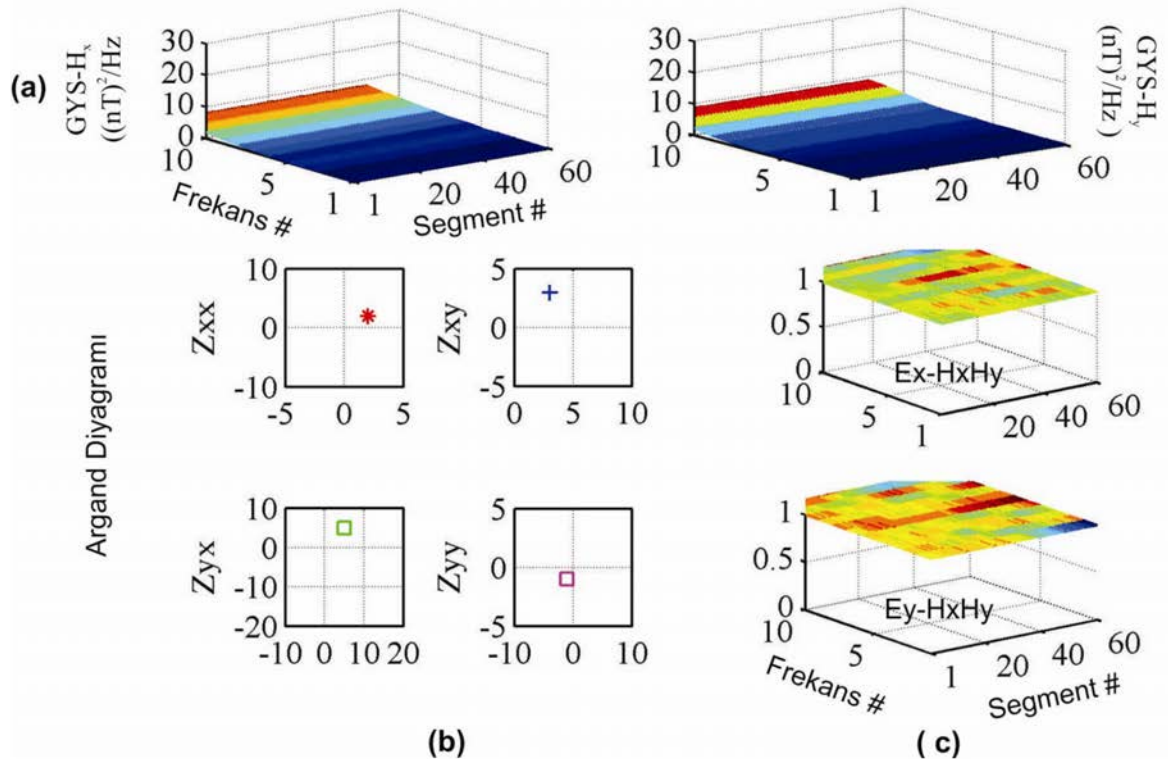


Şekil 8 (a) Eğitim sonucu (kırmızı hedef sınıflar, yeşil ağ sonucu elde edilen sınıflar) (b) 73. segment için ağ verimi (kesikli çizgi eğitimin durma kriteri).

Figure 8 (a) Training result (target classes are red and classes generated by the network are green) (b) Network performance for 73rd segment (intermittent line is training stop criteria).



Şekil 9.  $H_y$  bileşeni, YSA sınıflama sonucu (kırmızı hedef sınıflar, yeşil ağ sonucu elde edilen sınıflar).  
Figure 9.  $H_y$  component, ANN classification result (target classes are red and classes generated by the network are green).



Şekil 10. Gürültüsüz yapay veri (a) H bileşenleri güç yoğunluğu spektrumları (GYS) (b) en küçük kareler yöntemi ile hesaplanan empedansın Argand diyagramı (c)  $E_x-H_xH_y$  ve  $E_y-H_xH_y$  uyumunun segment ve frekans sayısına bağlı değişimleri.

Figure 10. Noise-free synthetic data (a) power spectral densities (PSD) of H components (b) Argand diagram of impedance calculated by least squares method (c)  $E_x-H_xH_y$  and  $E_y-H_xH_y$  coherence changes as per segment and frequency number.

bileşeni 2. frekansta geniş hata aralığı gibi düzensizlikler vardır (Şekil 17b). Uzak istasyon verisi kullanılarak uygulanan ağırlıklandırma yaklaşımı ise, gerek eğri yönelimi gerekse de hata

aralıklarının genişliği bakımından gürültü etkilerini düzeltme konusunda zayıf kalmıştır (Şekil 17, kırmızı renkle gösterilen değişimler). Oysa YSA sınıflaması ardından gürültüsüz veriden en

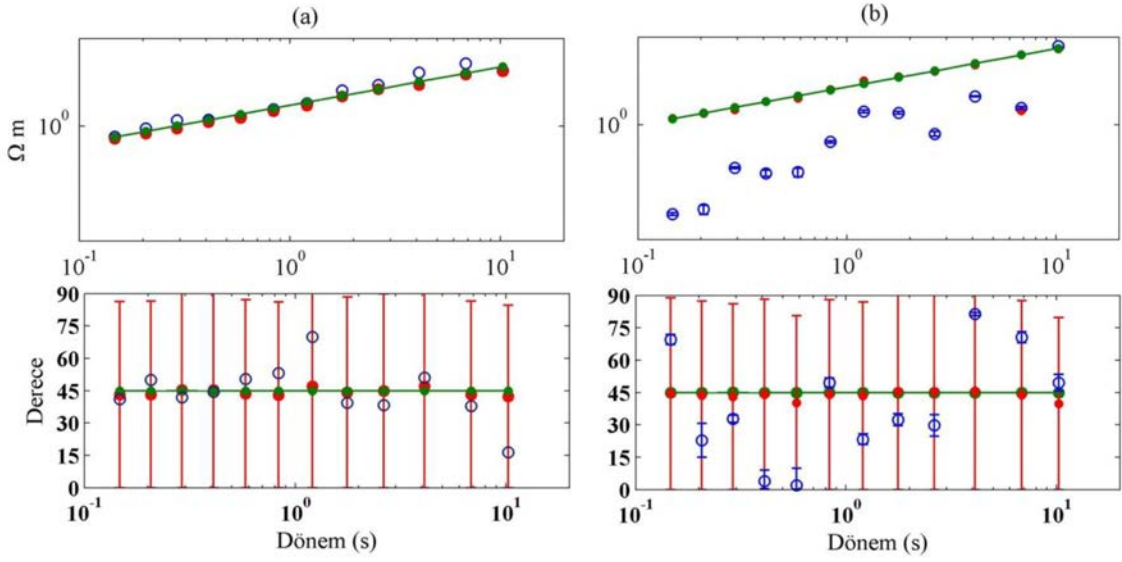
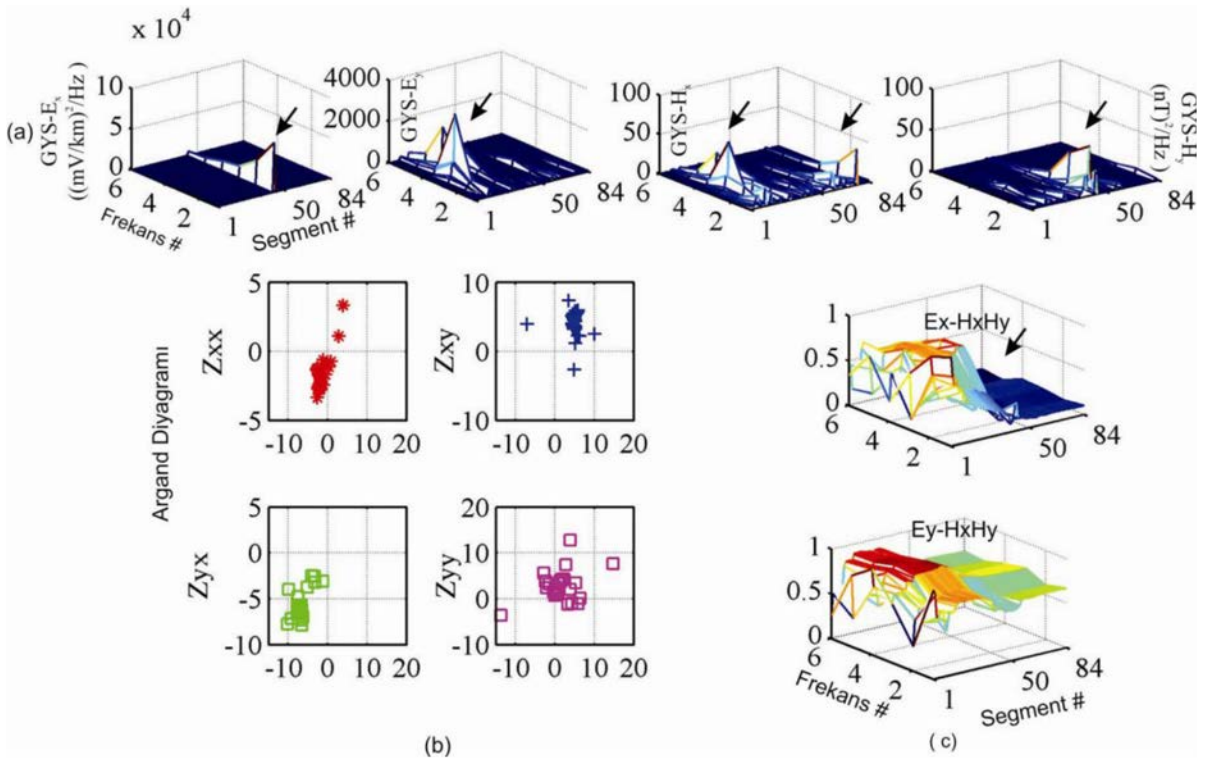


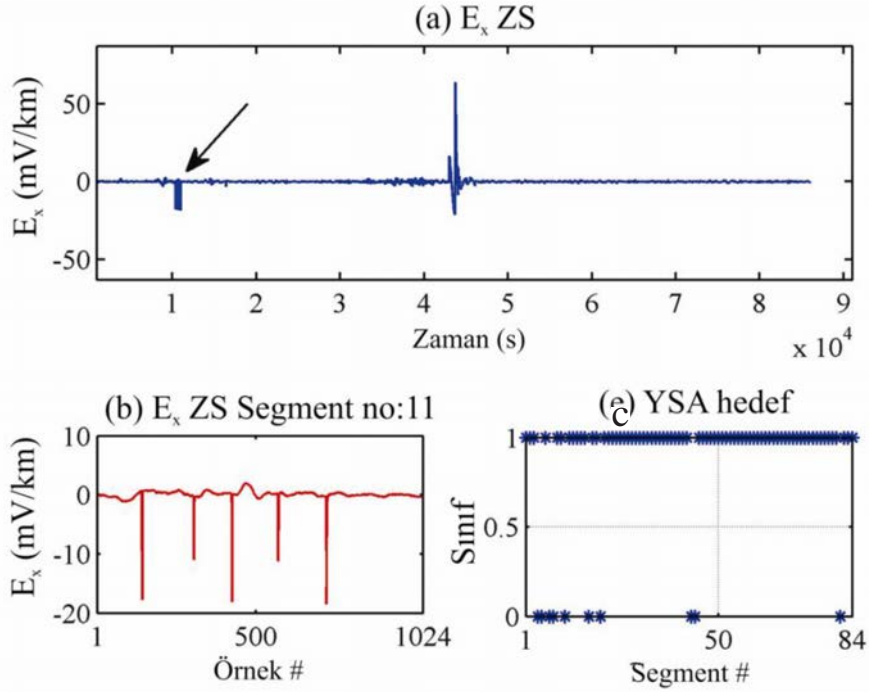
Figure 11. Yapay verinin görünür öz direnç ve faz değerleri (a) xy (b) yx yönleri (mavi; en küçük kareler yöntemi, kırmızı; ağırlıklandırma yöntemi ve yeşil; YSA sınıflaması sonrası en küçük kareler yöntemi).

Figure 11. Apperant resistivity and phase curves of synthetic data (a) xy (b) yx directions (blue; least squares method, red; robust method, green; least squares method after ANN classification).



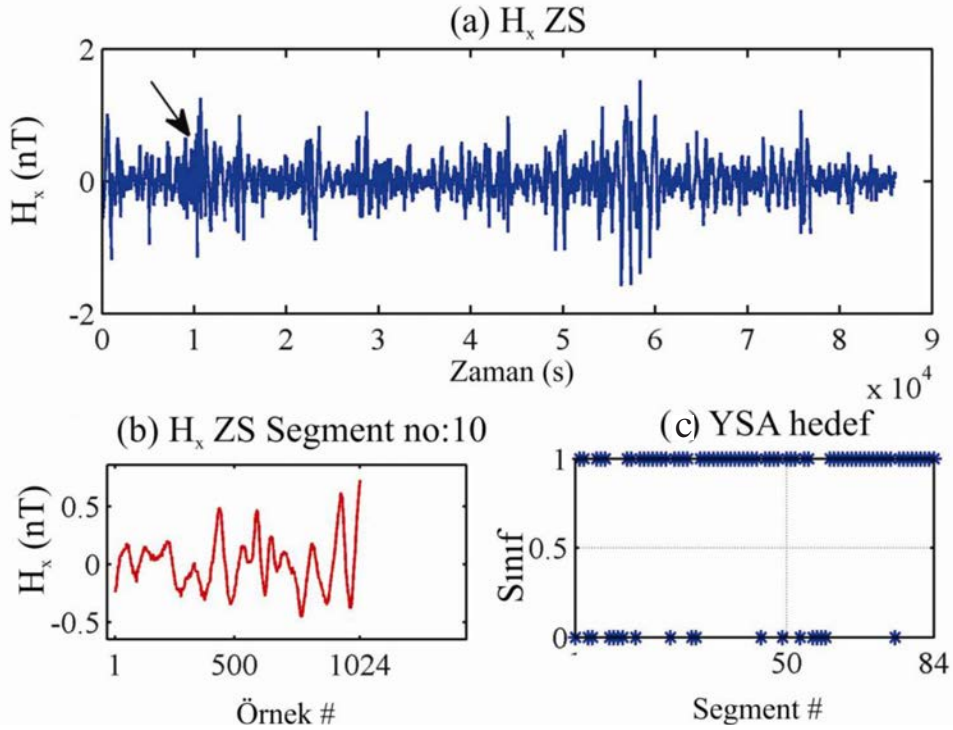
Şekil 12. Gürültülü arazi verisi (a) 4 bileşenin güç yoğunluğu spektrumları (GYS) (b) geleneksel yaklaşımla (uzak istasyon+ağırlıklandırma yöntemi) hesaplanan empedansın Argand diyagramı (5. frekans için) (c) Ex-HxHy ve Ey-HxHy uyumunun segment ve frekans sayısına bağlı değişimleri.

Figure 12. Noisy MT data (a) power spectral densities (PSD) of 4 components (b) Argand diagram of impedance calculated as conventional approach (remote reference+robust method) (for 5th frequency) (c) changes of Ex-HxHy and Ey-HxHy coherence on basis of segment and frequency number.




Şekil 13. YSA eğitim verisi,  $E_x$  bileşeni (a) tüm kayıt (ok işareti 11. segmenti göstermektedir), (b) 11. segment, iğnecik gürültüsü örneği (c) YSA hedef sınıflar.

Figure 13. ANN training data,  $E_x$  component (a) entire record (the arrow indicates 11th segment) (b) 11th segment, sample of spike noise (c) ANN target classes.



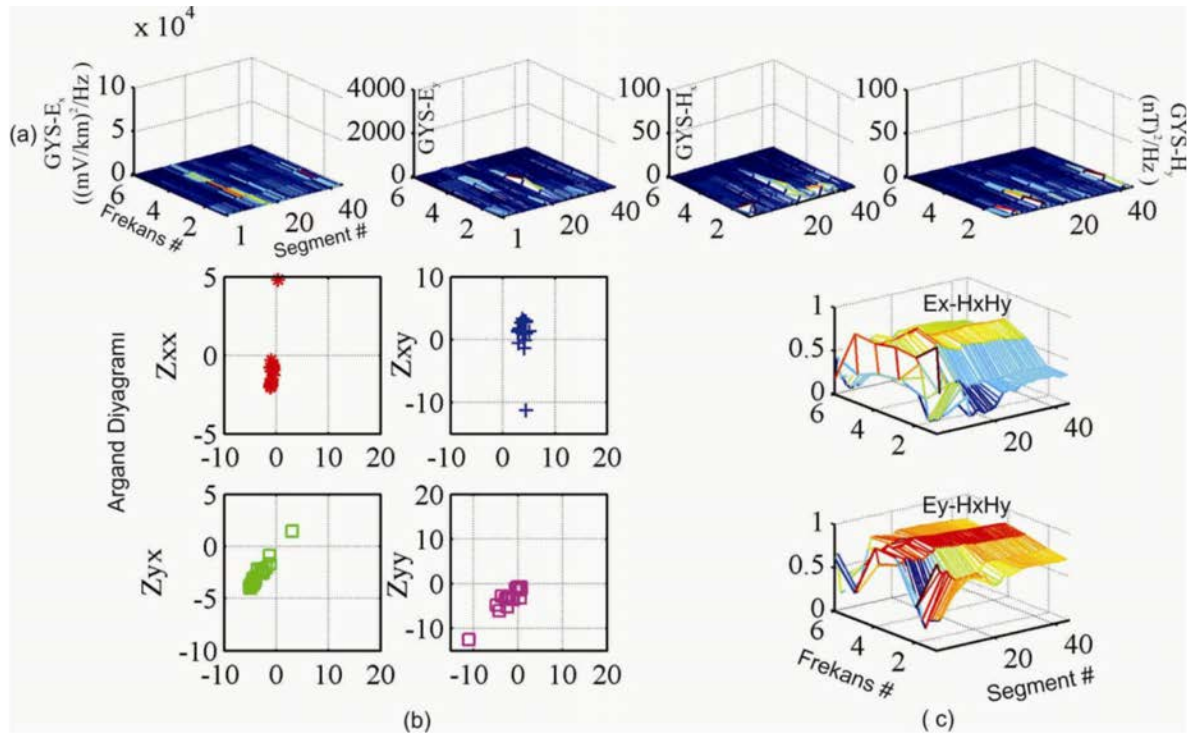
Şekil 14. YSA eğitim verisi,  $H_x$  bileşeni (a) tüm kayıt (ok işareti 10. segmenti göstermektedir), (b) 10. segment, güç yoğunluğu spektrumu gürültüsü örneği (c) YSA hedef sınıflar.

Figure 14. ANN training data,  $H_x$  component (a) entire record (the arrow indicates 10th segment) (b) 10th segment, sample of power spectral density noise (c) ANN target classes.



Şekil 15. Eğitim sonucu (ağ % 89 oranla doğru sınıflamıştır, kırmızı; hedef, yeşil; sınıflanmış veri).

Figure 15. Training result (network was classified with 89 % accuracy; target is red while classified data is green).



Şekil 16. Gürültüsüz arazi verisi (a) 4 bileşenin güç yoğunluğu spektrumları (GYS) (b) en küçük kareler yöntemi ile hesaplanan empedansın Argand diyagramı (5. frekans için) (c) Ex-HxHy ve Ey-HxHy uyumunun segment ve frekans sayısına bağlı değişimleri.

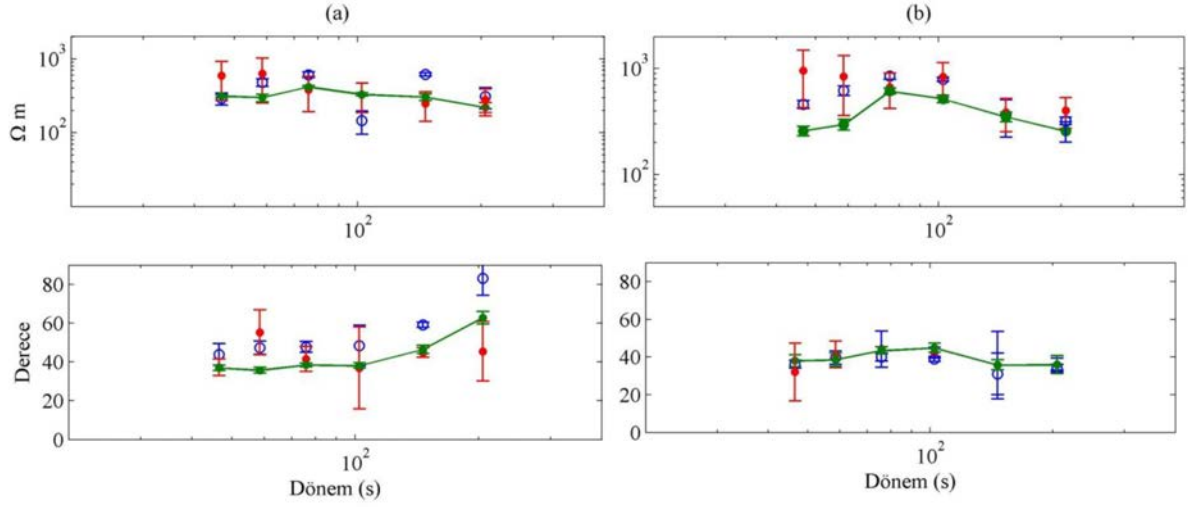
Figure 16. Noise-free field data (a) power spectral densities (PSD) of 4 components (b) Argand diagram of impedance calculated using least squares method (for 5th frequency) (c) changes of Ex-HxHy and Ey-HxHy coherence in accordance with segment and frequency number.

küçük kareler yöntemi ile hesaplanan görünür özdirenç ve faz, hem en küçük kareler yöntemi ve hem de geleneksel hesaplamayla elde edilen değerlere göre -eğri yönelimi ve hata aralıkları bakımlarından- düzelme göstermektedir (Şekil 17, yeşil renkle gösterilen değerler).

## SONUÇLAR VE TARTIŞMA

MT yöntemde gürültünün çeşitliliği, gürültü ve sinyalin benzer spektral özellikler göstermesi, uzak istasyon kaydının hiç olmaması ve/veya yerel gürültüden etkilenmesi, sinyal uyumunun düşük olması veya gürültü etkisiyle yanıltıcı ol-





Şekil 17. MT verisi, görünür öz direnç ve faz değerleri (a) xy (b) yx yönleri (mavi; en küçük kareler yöntemi, kırmızı; uzak istasyon+ağırlıklandırma yöntemi ve yeşil; YSA sınıflaması sonrası en küçük kareler yöntemi).  
 Figure 17. Apperant resistivity and phase curves of MT data (a) xy (b) yx directions (blue; least squares method, red; remote references+robust method, green; least squares method after ANN classification).

ması (ilişkili gürültü) gibi nedenlerle, geleneksel yaklaşımlar verideki gürültüyü tanımlamada ve elemde zayıf kalmaktadır. Bu nedenle bu çalışmada YSA yöntemi kullanılarak, farklı gürültü türlerinden etkilenen MT verisinin zaman ve frekans ortamı niteliklerine bağlı olarak sınıflandırılması ve gürültülü segmentlerin tanımlanmasına ilişkin bir uygulama gerçekleştirilmiştir.

Çalışmada gürültü tanıma/sınıflama için mühendislik çalışmalarında yaygın olarak uygulanan momentumlu geri yayımlı YSA modeli kullanılmıştır. Ağ topolojisini belirlerken ağın eğitiminin başarısı ve eğitim süresi bir kıstas olarak dikkate alınmıştır. Ağ modeli, yapay veri kullanılarak denetlenmiş ve ardından arazi verisine uygulanmıştır. Uygulamada sadece eğitim verisi için gürültü indeksi oluşturulmuş, diğer bileşenlerdeki gürültü YSA ile tanımlanmıştır.

Sonuç olarak YSA yöntemi ile yapay veride % 100, arazi verisinde % 89 doğrulukla gürültülü veri sınıflandırılmıştır. Bileşenlerde gürültülü olarak tanımlanan segmentlerin elenmesi ile de güç yoğunluğu spektrumları ve uyum değerlerindeki saçılımların asıl veriden elde edilenlere göre düzeldiği gözlenmiştir. Dahası en küçük kareler yöntemi ile hesaplanan görünür öz direnç ve faz, asıl veriden en küçük kareler ve geleneksel yol-

la hesaplanana oranla, eğri yönelimi ve hata oranları bakımından iyileşme göstermiştir.

YSA yöntemi kullanılarak MT verisindeki gürültüyü yok etmeye yönelik bu uygulama, işlem yükü ve zamanı bakımından elle yapılan görsel denetlemeye göre bir üstünlük sağladığı gibi, MT yöntemde geleneksel gürültü yok etme çalışmalarına bir seçenek (alternatif) olacak biçimde durağan sonuçlar üretmiştir.

## TEŞEKKÜR

Bu çalışmada kullanılan MT verisini sağlayan Sergio FONTES ve jeofizik birimi çalışanlarına (Observatorio Nacional-Brezilya) teşekkür ederiz.

## KAYNAKLAR

- Al-Nuaimy, W., Huang, Y., Nakhkash, M., Fang, M.T.C., Nguyen, V.T. ve Eriksen, A., 2000. Automatic detection of buried utilities and solid objects with GPR using neural networks and pattern recognition: Journal of Applied Geophysics, v. 43, Issues 2-4, 157-165.
- Ardjmandpour, N., Pain C, Singer J., Saunders J., Aristodemou E. ve Carter, J., 2011.

- Artificial neural network forward modeling and inversion of electrokinetic logging data, *Geophysical Prospecting*, 59, 721-748.
- Chave A. D. ve Thomson D. J., 1989. Some comments on magnetotelluric response function estimation. *J. Geophys. Res.*, 94: 14215-14225.
- Chave A. D. ve Thomson D. J., 2004. Bounded influence magnetotelluric response function estimation. *Geophys. J. Int.*, 157: 988-1006.
- Efe M. ve Kaynak O., 2000. Yapay sinir ağları ve uygulamaları. *Boğaziçi Üniv. Yay.*, 148 s.
- Egbert G. D. ve Booker J. R., 1986. Robust estimation of geomagnetic transfer functions. *Geophys. J. Roy Astr. Soc.*, 87: 173-194.
- Ehret, B., Leibniz Institute for Applied Geophysics, Stilleweg 2, 30655 Hannover, Germany, *Geoderma* 160 (2010) 111-125.
- El-Qady G. ve Ushijima K., 2001. Inversion of DC resistivity data using neural networks. *Geophysical Prospecting*, 49: 417-430.
- Gamble T. D., Goubau W. M. ve Clarke J., 1979. Magnetotelluric with a remote magnetic reference. *Geophysics*, 44 (1): 53-68.
- Goring D. G ve Nikora V. I, 2002. Despiking acoustic doppler velocimeter data, *J. Hydraul. Eng.* 128, 117.
- Goubau W. M., Gamble T. D. ve Clarke J., 1978. Magnetotelluric data analysis: removal of bias. *Geophysics*, 43: 1157-1166.
- Haykin S., 1999. *Neural network: a comprehensive foundation*, Second ed. Prentice Hall, New Jersey, USA.
- Jones A.G., Chave A. D., Egbert G., Auld D. ve Ahr K., 1989. A comparison of techniques for magnetotelluric response function estimation. *Journal of Geophysical Research*, 94 (10): 201-213.
- Kaftan I., Salk M ve Senol Y., 2011. Evaluation of gravity data by using artificial neural networks case study: Seferihisar geothermal area (Western Turkey), *Journal of Applied Geophysics*, 75, 711-718.
- Karnin, E. D., 1990. A simple procedure for pruning back-propagation trained neural networks, *IEEE IEEE Transaction on Neural Networks*, 1, 2, 239-242.
- Larsen J. C., Mackie R. L., Manzella A., Fiorde-lisi A. ve Rieven S., 1996. Robust smooth magnetotelluric transfer function. *Geophys. J. Int.*, 124: 801-819.
- Leung F.H.F, Lam H. K., Ling S. H. ve Peter K. S. Tam, 2003. Tuning of the structure and parameters of a neural network using an improved genetic algorithm, *IEEE Transaction on Neural Networks*, 14, 1, 79-88.
- Macias C.C., Sen M.K. ve Stoffa P.L., 2000. Artificial neural networks for parameter estimation in geophysics. *Geophysical Prospecting* 48, 21-47.
- Manoj C. ve Nagarajan N., 2003. The Application of artificial neural networks to magnetotelluric time-series analysis. *Geophys. J. Int.*, 153, 409-423.
- Mori N, Suzuki T. ve Kakuno S., 2007. Noise of acoustic doppler velocimeter data in bubbly flows, *J. Eng. Mech.* 133, 122.
- Öztemel E., 2003. *Yapay Sinir Ağları*. Papatya Yay., 232 s.
- Proakis J.G., Rader C.M., Fuyun L. ve Chrysos-tomosL., 1992. *Advanced digital signal processing*; Macmillan, New York.
- Poulton M., Stenberg B. ve Glass C., 1992. Location of subsurface targets in geophysical data using neural networks, *Geophysics*, 57, 1534-1544.
- Raiche A., 1991. A pattern recognition approach to geophysical inversion using neural nets. *Geophys. J. Int.*, 105, 629-648.
- Rittler O., Junge A. ve Dawes G. J. K., 1998. New equipment and processing for magnetotelluric remote reference observations. *Geophys. J. Int.*, 132,535-548.
- Rumelhart D.E., Hinton, G.E. ve Williams, R.J., 1986. *Parallel distributed processing: explorations in microstructure of cognition*. MIT Press Cambridge, MA, USA, 1,

- 318- 362 pp.
- Simpson F. ve Bahr K., 2005. Practical Magnetotellurics. Cambridge University Press., 254 pp.
- Sims W., Bostick F. ve Smith H., 1971. The estimation of magnetotelluric impedance tensor elements from measured data. *Geophysics*, 36, 938-942.
- Smirnov M. Y., 2003. Magnetotelluric data processing with a robust statistical procedure having a high breakdown point. *Geophys. J. Int.*, 152-1-7.
- Spichak, V.V., Fukuoka, K., Kobayashi, T., Mogi, T., Popova, I., ve Shima, H., 2002. Artificial neural network reconstruction of geoelectrical parameters of the Minou fault zone by scalar CSAMT data. *J. Appl. Geoph.*, 49 (1/2), 75-90.
- Spichak V. ve Popova I., 2000. Artificial neural network inversion of magnetotelluric data in terms of three-dimensional Earth macroparameters. *Geophys. J. Int.*, 142, 15-26.
- Swift C. M., 1967. A Magnetotelluric investigation of an electrical conductivity anomaly in the Southwestern United States. (Ph.D. dissertation), Mass. Institute of Technology.
- Şahin M., 2005. Çeşitli Geriye Yayılım Yapay Sinir Ağı Algoritmalarının Karşılaştırılması ve Bazı Uygulamaları. (Yüksek Lisans Tezi), Çanakkale.
- Ulugergerli E.U., Fontes S. L., Carvalho R. M., Germano C. R. ve Carrasquilla A., 2011. Magnetotelluric response estimates under the equatorial electrojet in Brazil, 12<sup>th</sup> International Congress of the Brazilian Geophysical Society August 15-18, 2011, Rio de Janeiro, Brazil.
- van der Baan M. ve Jutten C., 2000. Neural networks in geophysical applications. *Geophysics*, 65: 1032 - 1047.
- Vozoff K., 1991. The magnetotelluric method. In: M.N. Nabighian (Ed). *Electromagnetic Methods in Applied Geophysics*, SEG, Tulsa, OK, 2: 641-711.
- Weckmann U., Magunia A. ve Ritter O., 2005. Effective noise separation for magnetotelluric single site data processing using a frequency domain selection scheme. *Geophys. J. Int.*, 161, 635-652.
- Zhang Y. ve Paulson K. V., 1997. magnetotelluric inversion using regularized hopfield neural networks. *Geophysical Prospecting*, 45, 725-743.
- Zurada J.M., 1992. Introduction to artificial neural systems. West Pub. Comp., 679 pp.

