

Depreme ilişkin olağan dışı sinyal değişiminin YSA ile saptanması

Mehmet Sıraç ÖZERDEM*, **A.Coşkun SÖNMEZ**

İTÜ Elektrik Elektronik Fakültesi, Bilgisayar Mühendisliği Bölümü, 34390, Maslak, İstanbul

Özet

Kayaç deformasyonu sonucu oluşan piezo-elektrik kökenli elektrik alan ölçüm değerleri içinde deprem öncesi oluştuğu öngörülen özel bir örüntünün varlığı saptanmıştır. Bu çalışmada deprem ile ilişkilendirilebilen bu değişimin saptanması hedeflenmiştir. İlk aşamada, işlenen örüntü boyutunun büyük olması nedeniyle Hebbian tabanlı ilkesel bileşen analizi kullanılarak örüntü boyutu indirgenmiştir. İndirgenen örüntüler ile ağı eğitimi sağlanmıştır. Eğitilen ağı çıkışında, giriş örüntüsünün içeriğine bağlı olarak olağan veya olağan dışı örüntü olduğuna ilişkin sonuç üreten bir düzenek gerçekleştirilmiştir. Gerçeklenen uygulamalarda, kayaç gerginliği sonucu oluşan elektriksel alanın içinde yer alan deprem haberci örüntüsü yüksek bir olasılıkla saptanmıştır.

Anahtar Kelimeler: *Deprem, örüntü sınıflama, yapay sinir ağları*

Classification of anomaly patterns with using neural networks

Abstract

Earthquake is a natural event which has no linear property in time and space and cannot be modelled exactly. Estimation of an earthquake by means of pattern learning and recognition property of artificial neural networks (ANN) is the essential goal of this study. The values obtained through the sensor to measure earthquake-related monopolar electric field constitute time dependent patterns. These patterns are analysed and evaluated by the help of ANN. Phases of evaluation process can be explained briefly : the computation load of the artificial neural network was increased because of the large pattern size. So, in order to decrease this computational load the pattern size is reduced by an Hebbian based component analysis methods. In the next phase, these reduced-size patterns are used as training set for the process of artificial neural network training. At the output layer of network, a mechanism is realized that produces results related with pattern's being normal or abnormal and this result depend on the input pattern's content. As a result of applications covered in this study, the measurement of electric field resulted from regional tectonic stress and the earthquake forerunner pattern which resides in this field is detected with a high success rate. In addition, it is observed that learning is improved and success is increased by the increase in the number of pattern which includes abnormal change.

Keywords: *Artificial neural networks, earthquake, pattern classification.*

*Yazışmaların yapılacağı yazar: Mehmet Sıraç ÖZERDEM. sozerdem@cs.itu.edu.tr; Tel: (212) 285 69 86.

Bu makale, birinci yazar tarafından İTÜ Elektrik-Elektronik Fakültesi'nde tamamlanmış olan "Sismik anomalilerin YSA yöntemi ile tanınması ve sınıflandırılması" adlı doktora tezinden hazırlanmıştır. Makale metni 02.06.2003 tarihinde dergiye ulaşmış, 09.12.2003 tarihinde basım kararı alınmıştır. Makale ile ilgili tartışmalar 29.02.2004 tarihine kadar dergiye gönderilmelidir.

Giriş

Depremlerin öncesinde meydana gelen çeşitli fiziksel olağan dışı olaylar dikkate alınarak, olası depremi öngörmek ya da kestirmek için çeşitli fiziksel büyüklükler gözlemlenmiştir ve bu alanda bir çok çalışmanın devam ettiği bilinmektedir. Kuyu su seviye ölçümleri (Tiecheng ve Baoyin, 1995), yeraltı kaynak suyu sıcaklık değişimleri (Zhonghao, 1999), radon gazı yayılması (Yong ve Wai, 1995), GPS verileri ile uzun süreli bölgesel ötelemelerin belirlenmesi (Reilinger ve Barka, 1997), yerin manyetik alanındaki sapma miktarının ölçülmesi, deprem öncesinde gözlenen olağan dışı hayvan davranışları (Buskirk vd, 1981) gibi bir çok değişime bakılarak depremin yaklaşık yeri, zamanı ve büyüklüğü ile bir depremi önceden kestirmeye yönelik başarılı bir yöntem ortaya konulamamıştır. İTÜ Elektrik-Elektronik ve Maden Fakülteleri “Elektrostatik Kayaç Gerginlik İzleme Yöntemi ile Deprem Tahmin Sistemi (EKGDT)” isimli bir ortak projeyi 1999 yılında başlatmışlardır. Proje kapsamında özel olarak geliştirilmiş tek kutuplu elektrik alan (TEA) ölçüm duyargası (Canyaran ve Üstündağ, 1999) ile depremlerin önceden belirlenmesi için 16 istasyonlu bir ağ kurulmuştur. TEA ölçüm duyargası ile elde edilen verilerin değerlendirilmesinde yapay sinir ağlarının (YSA) öğrenme ve tanıma özelliklerinden faydalanılmıştır.

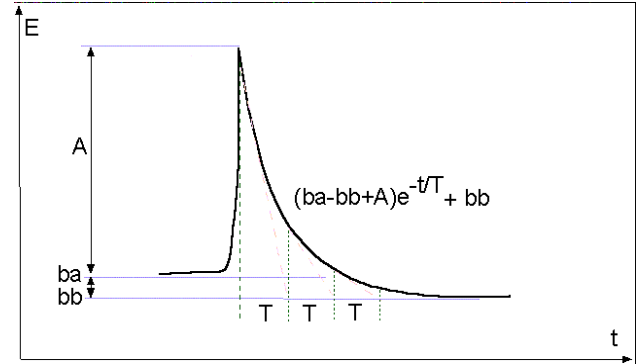
Bir yapay sinir ağı, birbiriyle etkileşim içindeki pek çok yapay nöronun paralel bağlı bir hiyerarşik organizasyonudur (Zurada, 1992). Bilgilerin kurallar şeklinde açıklandığı klasik uzman sistemlerinin tersine, YSA gösterilen örnekten öğrenerek kendi kurallarını oluşturur (Rojas, 1996). YSA'nın uyarlanır elemanlar ile yoğun bir şekilde paralel olarak bağlanmasıyla oluştuğu ve hiyerarşik organizasyonları düzenlenmiş yapılar olduğu belirtilmiştir (Kohonen, 1980). Ayrıca bu yapının, biyolojik sistemlerin gerçek dünyadaki cisimleri algılayabilmesine benzer bir yaklaşım içerdiği vurgulanmıştır.

YSA'da öğrenme; giriş örneklerine veya bu girişlerin yanısıra ilgili çıkışlara bağlı olarak ağın bağlantı ağırlıklarının değiştirilmesiyle gerçekleşir (Karlık, 1994). Öğreticili ve öğreticisiz

öğrenme olmak üzere iki tür temel öğrenme stratejisi vardır (Efe ve Kaynak, 2000). Her iki strateji arasındaki temel fark, istenen çıkışın öğreticili öğrenmede bilindiği ancak öğreticisiz öğrenmede bilinmediğidir. YSA ne kadar çok olayla ilgili değişik özelliklere sahip örnek ile eğitilir ise öğrenebilecekleri olay ve tanıyabilecekleri obje sayısı artarken hata oranı azalacaktır.

Deprem öncesi değişimler

Bu çalışma kapsamında, depremle ilişkili veriler ürettiği savunulan TEA ölçüm duyargası ile elde edilen veriler üzerinde çalışılmıştır. Şekil 1'de bir deprem öncesi TEA ölçüm duyargasından elde edilen verilerle oluşan örüntü gösterilmiştir. Bu örüntü ile ilgili temel tanımlar şöyle açıklanabilir: A değişkeni, olağan değer ile olağan dışı değer tepe noktası arasındaki genlik farkını, ba değişkeni, olağan dışı davranışın başladığı andaki değeri, bb değişkeni, olağan dışı davranışın aldığı son değeri ve Δt değişkeni ise olağan dışı davranışın düşüş zaman katsayısını simgeler.



Şekil 1. Deprem öncesi görüldüğü varsayılan olağan dışı örüntü

Yer bilimciler örüntünün genliği ile depremin şiddeti arasındaki ilişkiyi şu ana kadar tanımlayamamışlardır. Ancak EKGDT proje grubu genlik (A), ba-bb farkı ve Δt değerlerinden depremin ölçüm istasyonuna uzaklığı, depremin şiddeti ve süresinin kestirilebileceğini değerlendirmektedir. EKGDT proje grubunu Şekil 1'de gösterilen örüntünün deprem habercisi olduğu görüşünü savunmaktadır. Nitekim benzer örüntüler laboratuvar çalışmalarında kırılma öncesi

elektrik yük değişimi kayıtlarında da görülmüştür (Matsuda vd., 2001). Olayın matematiksel modeline göre beklenen değişim, saha ölçümlerinden elde edilen örüntüler ile uyuşmaktadır. Bu çalışmamızda Şekil 1’de tanımlanan tipik örüntü Çok Katmanlı Algılayıcıda (ÇKA) eğitim kümesi olarak kullanılmıştır.

Deprem habercisi olan örüntü süresinin belirlenmesi

EKGDT grubu tarafından yapılan ölçümler sonunda deprem haberci örüntüsünün en kısa 60 saniyede oluştuğunu göstermektedir. Örüntünün kıvraklığı ve günümüz bilgisayar teknolojileri ele alınarak 5 saniyede bir örnek alınmasının uygun olacağı sonucuna varılmıştır.

2000 yılından günümüze kadar, 16 değişik istasyonda yapılan deneyler sonucu örüntünün oluşması için yaklaşık 1.5 saat gibi bir sürenin gerektiği gözlemlenmiştir. Bunun sonucu olarak her örüntünün yaklaşık 1000 sayısal değerden oluştuğu açıktır.

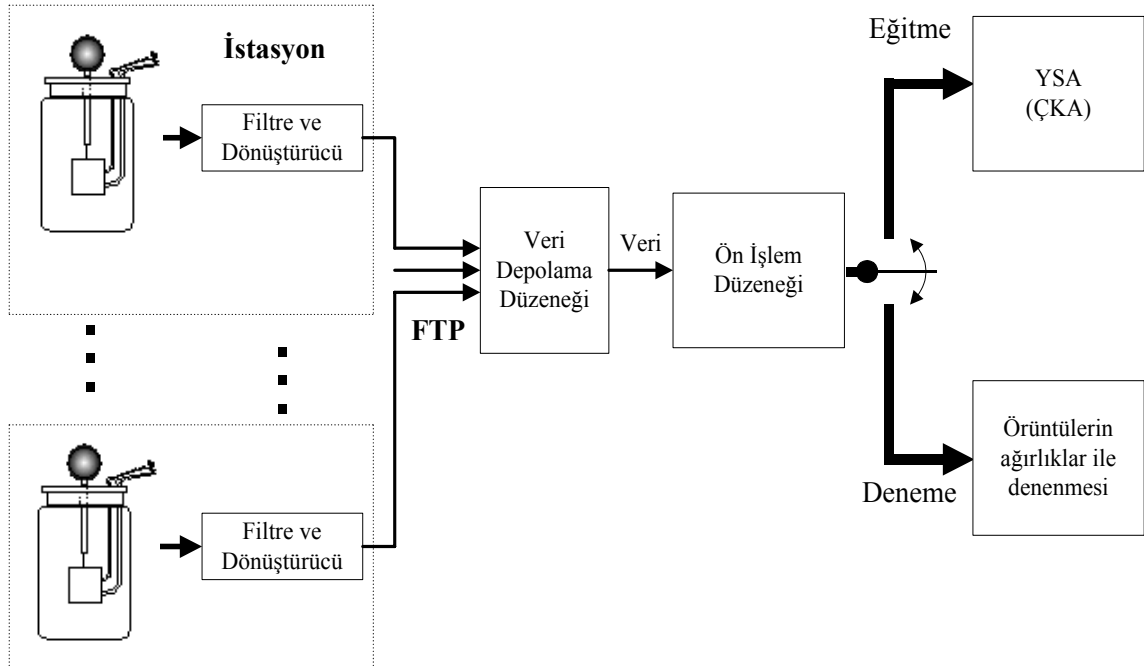
Hesaplama yükünü azaltmak için ilk aşamada Hebbian tabanlı ilkesel bileşen analiz yöntemi kullanılarak 1000 örnek sayısı 200’e indirgenmiştir.

Olağan dışı örüntünün saptanması için gerçekleştirilen öğrenme ve saptama düzeneği

Ölçme istasyonlarında, Femto Coulomb mertebesinde yük değişimlerine duyarlı bir TEA ölçme duyargasından elde edilen analog işaretler, koşullandırılarak sayısalaya dönüştürülmekte ve sayısal adaptif filtrenin ardından FTP ile internet üzerinden bir veri toplama merkezine gönderilmektedir. Çalışmanın hedef alanı olan Marmara bölgesi’nde kurulan 16 istasyondan toplanan verilerin oluşturduğu örüntüler Şekil 2’de görüldüğü üzere ön işlemlerden geçirilir ve YSA’nın giriş örüntüleri olarak kullanılır.

Şekil 2’deki düzende ön işlem aşaması olarak görülen kısımda veriler YSA’da işlenebilecek örüntüler kümesi haline dönüştürülür. Ön işlem düzeneği normalizasyon, tekrarlı blokların oluşumu ve indirgeme aşamalarını kapsar.

TEA ölçüm verilerinin tanımlı olduğu aralık [9000 13000] ile ağda kullanılan aktivasyon fonksiyonlarının [-1 1] gibi farklı değer aralıklarında olmalarından dolayı doğrusal ölçekleme yapılmıştır. Doğrusal ölçekleme ile bu aralık [0.1 0.9] değer aralığına taşınmıştır.



Şekil 2. Örüntü saptama düzeneği

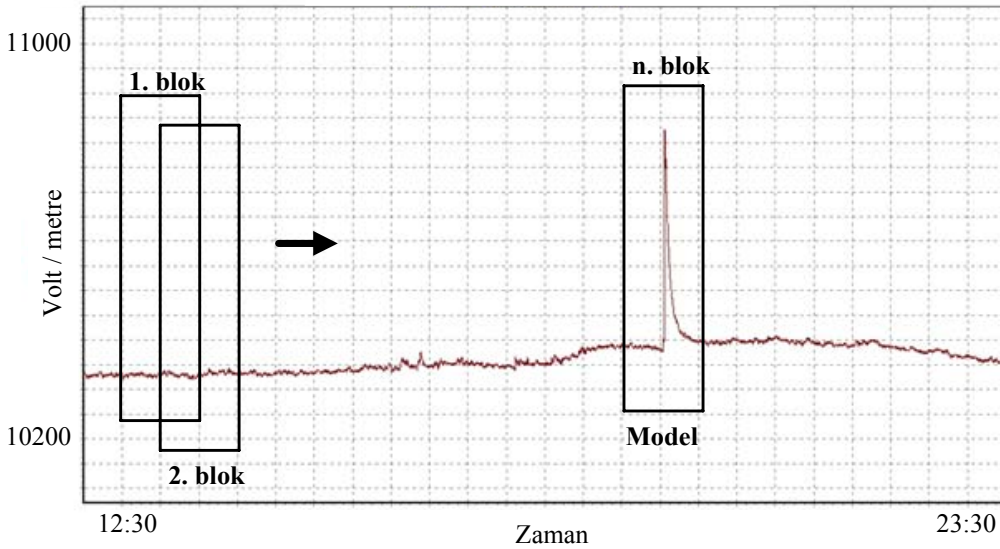
Blokların oluşumu aşamasında, değişim içerisinde bir olağan dışı değişimi kaçırmamak amacıyla verilerin tekrarlı bloklar haline dönüşümü sağlanır. TEA ölçümlerinin taranmasında izlenen yöntem; her yeni veri girişinde son 12 saatlik kayıt üzerinden 1.5 saatlik bir pencerenin kaydırılmasıdır (Şekil 3).

Örüntü boyutunun indirgenmesi ve benzerlik kavramı

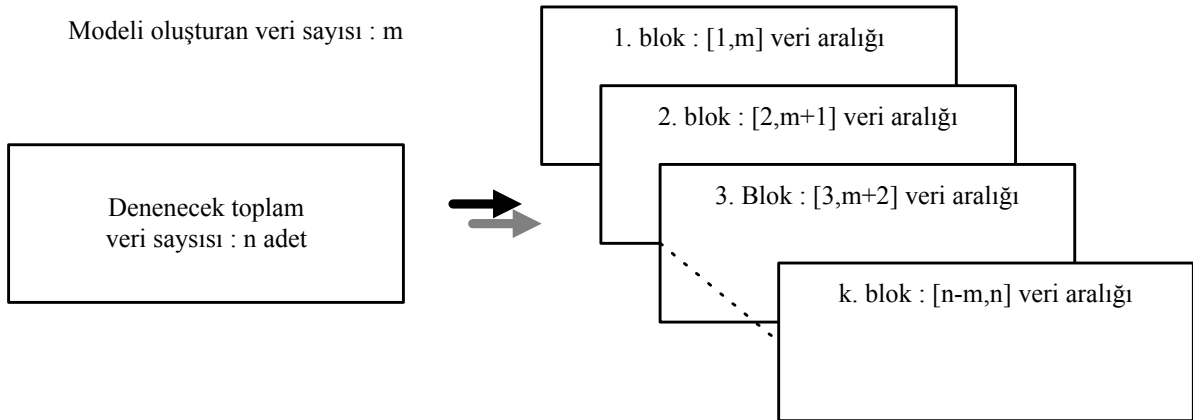
TEA duyargasından gelen verilerin sayısı bilgisayar işlem yükünü zorlamaktadır. Bu nedenle bilgi kaybı olmaksızın örüntü içindeki veri sayısının indirgenmesi gerekmektedir. Bir veri kümesi içindeki verilerin sayısını sınırlı bir

bilgi kaybı kabul edilerek azaltmak için Hebbian tabanlı ilkesel bileşen analiz yöntemi kullanılabilir (Haykin, 1999).

Öğreticisiz öğrenme (unsupervised learning) stratejilerinden Hebbian algoritmasında amaç, her özdüzenlemeli YSA'da olduğu gibi eğitim kümesinde önemli örüntüleri yakalamak veya giriş verilerinin özelliklerini saptamaktır. Hebbian tabanlı temel bileşen analizi için tek katmandan oluşan ileri beslemeli bir YSA örneği Şekil 4'te gösterilmiştir. Yapı itibariyle dikkate alınması gereken iki önemli nokta: a)YSA'yı oluşturan her nöron çıkışının lineer olması, b)YSA'nın bilinen m tane giriş sayısının l tane çıkış sayısından büyük ($l < m$) olmasıdır.

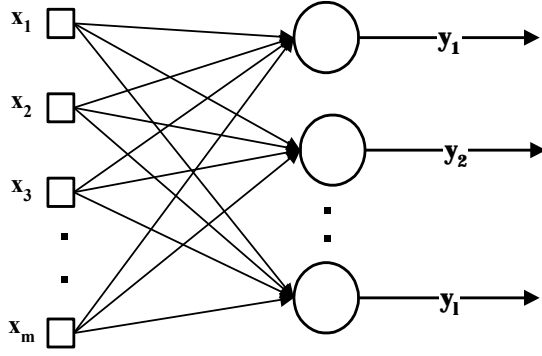


a) Pencerenin veri üzerinde kaydırılması



b) Taranan pencere ile oluşan veri blokları

Şekil 3. Tekrarlı blokların oluşturulması



Şekil 4. İleri beslemeli bir YSA yapısı

Ağın çıkışı:

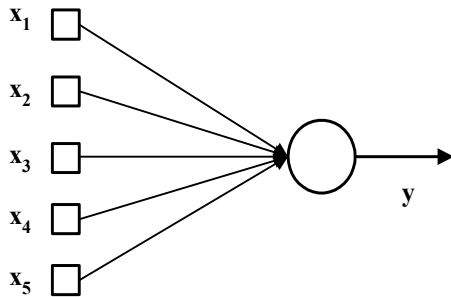
$$y_i(n) = \sum_{i=1}^m w_{ji}(n)x_i(n) \quad j=1,2,\dots,l \quad (1)$$

ifadesi ile hesaplanır (Haykin, 1999). Genelleştirilmiş Hebbian öğrenme algoritması uygulanarak ağırlıklar değiştirilir. Ağırlıkların değişimi:

$$\Delta w_{ji}(n) = \eta(y_i(n)x_i(n) - y_i(n) \sum_{k=1}^j w_{ki}(n)y_k(n)) \quad \begin{matrix} i = 1,2,\dots,m \\ j = 1,2,\dots,l \end{matrix} \quad (2)$$

$$w_{ji}(n+1) = w_{ji}(n) + \Delta w_{ji}(n) \quad (3)$$

bağıntılarına göre hesaplanır. Boyutu (m,1) olan giriş vektörü $x_i(n)$ olarak, öğrenme katsayısı η olarak ve çıkış nöron sayısı ise l olarak sembolize edilmiştir. Bu çalışmada Şekil 4'te verilen yapay sinir ağına karşılık Şekil 5'te verilen yapının kullanılabilceği tarafımızdan önerilmiştir.



Şekil 5. Gerçeklenen YSA yapısı

Ağın eğitimi esnasında ağırlık katsayılarının artış miktarı, eğitimi durdurma ölçütü olarak alınır. Ağırlığın artış miktarı belirli bir eşik seviyesinin altına düşmesi durumunda eğitim işlemi sonlandırılır. Bu çalışmada, örüntüye ilişkin karakteristik bilgileri kaybetmeden Hebbian yöntemi ile örüntüdeki örnek sayısının azaltılması amaçlanmıştır. Asıl verilerden oluşan örüntüye $y(t)$ ve indirgenmiş örüntüye de $x(t)$ dersek, bu iki örüntünün birbirine benzerlik değerini

$$B = \max_{\forall t \in [a,b]} |y(t) - x(t)| \quad (4)$$

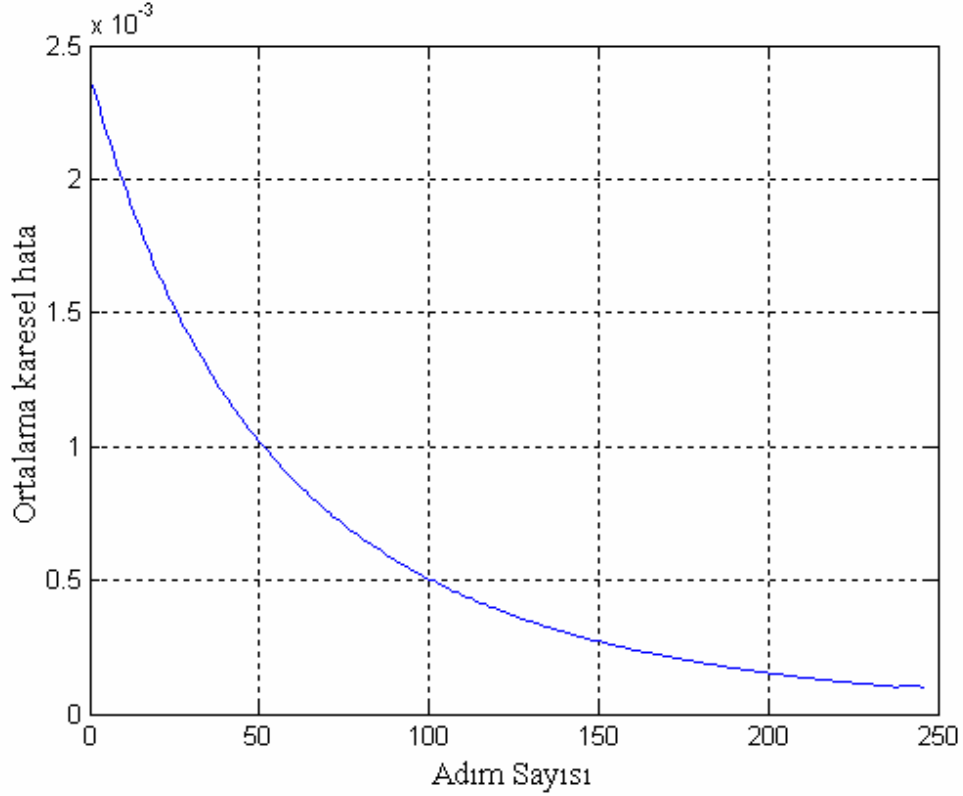
ile ifade edebiliriz. B için belirlenen bir değer asıl ve indirgenmiş örüntülerin birbirlerine ne kadar benzer olduğunun ölçütüdür. Gerçeklenen çalışmalar sonucunda, $B=0.1$ benzerliğin yeterli sayılabilirliği varsayımıyla kalkarak yapılan deneylerde 5-1 oranında indirgemenin uygun olduğu sonuca varılmıştır. 5-1 oranında indirgeme benimsendiğinden ağın öğrenme sürecindeki başarımının değişimi Şekil 6'da gösterilmiştir. Gerçeklenen analizde öğrenme katsayısı $\eta=0.01$ alınmış, işlem 246 adımda tamamlanmıştır. Analizi sonlandırmak için eşik seviyesi de $e=0.0001$ alınmıştır.

Yine aynı deneyde asıl veri ve indirgenmiş veri şekilleri Şekil 7'de gösterilmiştir.

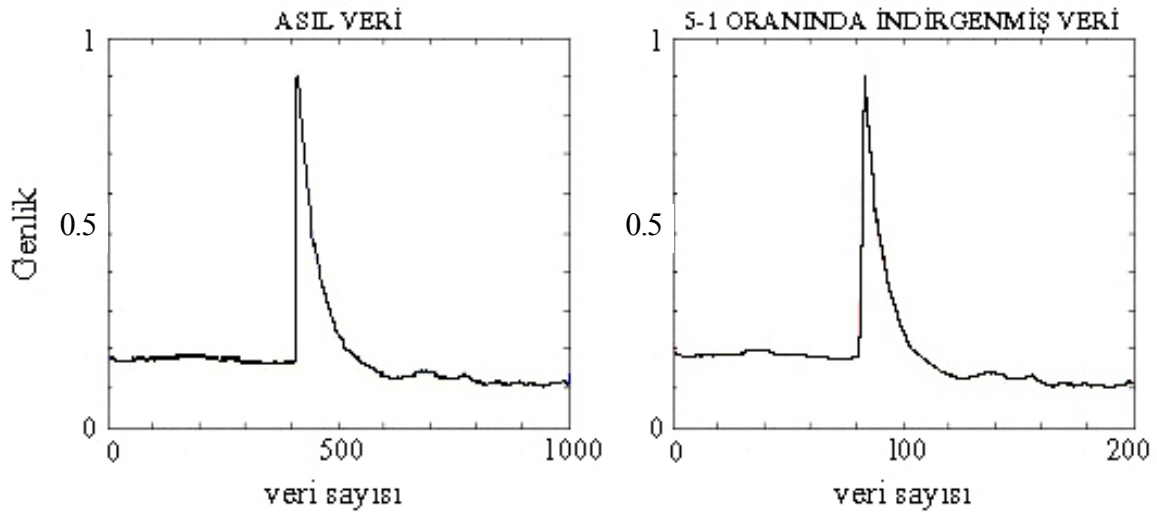
Boyutu indirgenmiş örüntü, eğitilmek üzere geriye yayılma algoritmasının kullanıldığı çok katmanlı algılayıcının (Multi-layer perceptron) giriş vektörü olarak kullanılır.

Geriye yayılma algoritması ile örüntü saptama

Yapay sinir ağlarında ileri yol yapısındaki ağlara ait parametrelerin güncellenmesi için literatürde sıkça karşılaşılan yöntem olan geriye yayılma algoritması kullanılmıştır. Bu yöntem, hataların giriş olarak uygulandığı kuadratik bir amaç ölçüt fonksiyonunu minimize edecek şekilde ağ parametrelerinin uyarlanmasına dayanır (Özerdem vd., 2002). Ağ yapısı en az üç katmandan oluşur. Bunlar giriş, gizli ve çıkış katmanlarıdır.



Şekil 6. Başarım değişimi



Şekil 7. Örüntü boyutunun indirgenmesi

Verilen eğitim kümesi için ortalama karesel hata öğrenme performansının ölçütü olarak alınır ve bu amaç ölçütünü en küçülten parametreler belirlenir. Ortalama hata:

$$e_j(n) = d_j(n) - y_j(n) \quad (5)$$

$$\varepsilon(n) = \frac{1}{2P} \sum_{j \in C} \sum_{n=1}^N e_j^2(n) \quad (6)$$

ile ifade edilir. Burada e hata işaretini, n adım sayısını, d çıkışta istenilen vektörü, y ağıın ürettiği çıkış vektörünü, P örüntü sayısını ve C çıkış katmanındaki nöron sayısını temsil eder.

Gizli katman ile çıkış katmanı arasındaki ağırlık katsayılarının değişimi:

$$\Delta w_{ji}(n) = \eta \delta_j(n) y_i(n) \quad (7)$$

$$\delta_j(n) = e_j(n) \varphi' \left(\sum_{i=0}^m w_{ji}(n) y_i(n) \right) \quad (8)$$

bağıntılarıyla hesaplanır. Giriş katmanı ile gizli katman arasındaki ağırlık katsayıları:

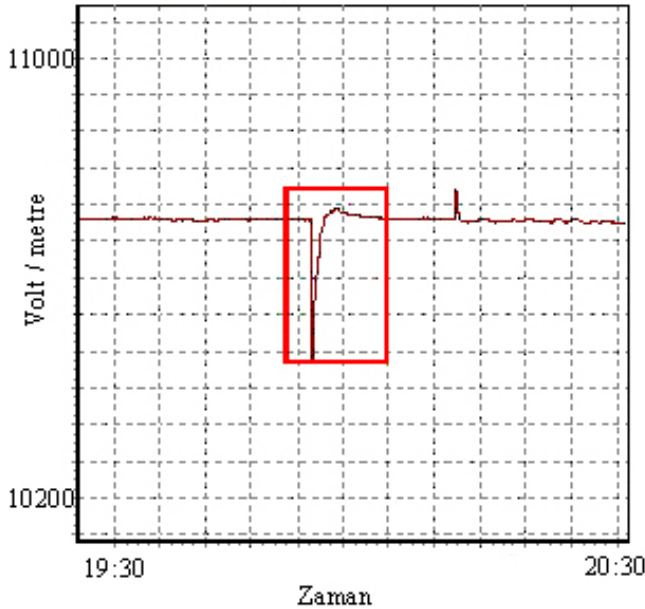
$$\delta_j(n) = \varphi' \left(\sum_{i=0}^m w_{ji}(n) y_i(n) \right) \sum_k \delta_k(n) w_{kj}(n) \quad (9)$$

ile belirlenir. η öğrenme katsayısını simgeler ve probleme göre farklı değerler alır. Rumelhart tarafından, ağırlık yakınsamaması durumunda α momentum terimini de içerecek şekilde ağırlıkların ayarlanmasını sağlayan formül aşağıdaki şekilde genelleştirilmiştir (Haykin, 1999).

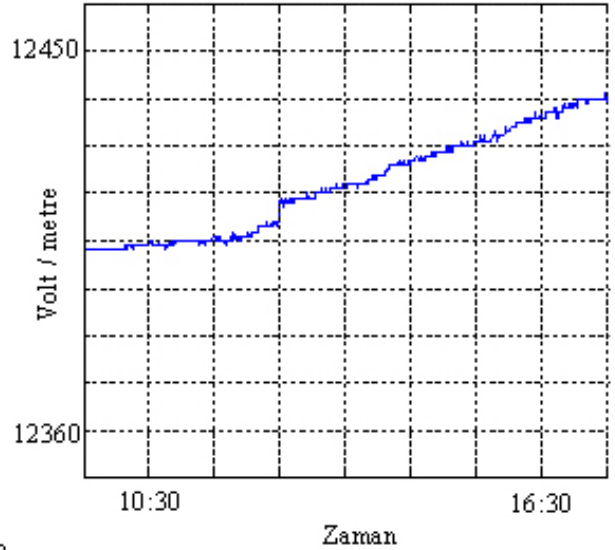
$$\Delta w_{ji}(n) = \alpha \Delta w_{ji}(n-1) + \eta \delta_j(n) y_i(n) \quad (10)$$

Gerçeklenen uygulamada toplam 27 deprem haberci örüntüsü olup, bunlardan 17 tanesi eğitim amaçlı ve 10 tanesi ise deneme amaçlı kullanılmıştır. Olağan dışı değişim içermeyen 20 örüntü eğitim kümesine dahil edilerek, toplam 37 örüntüden oluşan bir eğitim kümesi oluşturulmuştur. Deneme kümesine ise toplam 5 olağan dışı değişim içermeyen örüntü dahil edilerek, toplam 15 örüntüden oluşan bir deneme kümesi oluşturulmuştur. Ağın eğitiminde kullanılan örüntülerden iki tipik örnek Şekil 8'de gösterilmiştir. Ön işlem olarak kullanılan Hebbian ile veri (5-1) oranında sıkıştırılmış ve örüntü boyutu 1000'den 200'e indirgenmiştir. Dolayısıyla, YSA giriş katmanının nöron sayısı 200 olacaktır.

YSA'da hedeflenen küme örüntülerine ilişkin deprem habercisi olan örüntüler [1 0] şeklinde, olağan dışı davranış içermeyen örüntüler ise [0 1] şeklinde kodlanmıştır. Burada amaç mevcut çalışma bölgesini iki sınıfa ayırmaktır. Kodlamada Hamming uzaklığının 1 yerine 2 alınması, sınıflamanın başarı yüzdesini artırmıştır. Uygulamada gerçekleştirilen ağ yapısı Şekil 9'da gösterilmiştir.

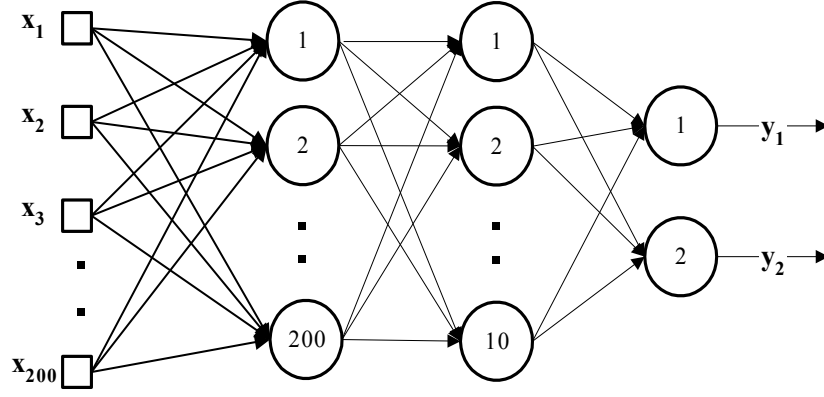


a)



b)

Şekil 8. a) Deprem öncesi sinyal içeren Sakarya istasyon kaydı (05.12.2001)
b) Olağan dışı değişim içeren Balıkesir istasyon kaydı (28.06.2001)



Şekil 9. Olağan dışı örüntü saptama için gerçekleştirilen çok katmanlı ağ modeli

Eğitimi durdurma ölçütü olarak, ortalama karesel hatanın belirli bir eşik değerinden daha küçük bir değere düşmesi durumu dikkate alınmıştır. Delta öğrenme kuralı ile gerçekleştirilen çalışmada, son katmandan giriş katmanına doğru (backward) delta değerinin düşmesi, her katmanda öğrenme katsayısını farklı almamıza neden olmuştur.

Ağın çıkış değerlerinin (0,1) arasında olması beklendiğinden çıkış katmanında sigmoid fonksiyonu kullanılmıştır. Eğitim sürecinde farklı YSA parametreleri ile çeşitli çalışmalar gerçekleştirilmiş olup, bunlardan üç tanesinin ölçütleri ve başarımları Tablo 1’de gösterilmiştir.

Tablo 1’de görüldüğü üzere, farklı ağ parametre katsayılarından oluşan (200-200-10-2) yapıda bir ağ modeli üzerinde çalışılmıştır. Eğitim aşamasında ortalama karesel hatanın adım sayısı ile üstel bir biçimde azaldığı saptanmıştır. Bu tür bir değişim eğitim aşamasında beklenen bir değişimdir.

Örüntülerin deneme aşaması, eğitim aşamasında olduğu gibi ön işlemler içermektedir. Deneme kümesi için belirlenmiş örüntülerin eğitilmiş ağırlıklar ile denemesi sonucu elde edilen çıkışlar Tablo 2’de gösterilmiştir. Tablo 2’nin ilk sütununda elde edilmesi beklenen kodlar ve diğer sütunlarda gerçekleştirilen üç uygulamanın deneme sonuçları yer almaktadır. Sonuçlardan koyu renkli yazılmış olanlar, yanlış sınıflandırılmış örüntülerdir. Tablo 2’de görüldüğü üzere, 1. ve 2. uygulamada 1. ve 9. örüntülerinin yanlış

sınıflandırılmış oldukları saptanmıştır. 3. uygulamada ise 1. örüntünün yanlış sınıflandırılması, uygun parametre ölçütlerinin değişimiyle giderilmiştir. 9. deneme örüntüsü ise yapılan tüm uygulamaların sonucunda istenilen sınıfa dahil edilememiştir. Bunun nedeni, deprem habercisi olduğu varsayılan değişimin genliğinin oldukça küçük olmasıdır. Olağan dışı değişimlerin bulunduğu örüntülerin tamamıyla ayrıştırılması, saptanan diğer bir önemli sonuçtur.

Sonuçlar ve tartışma

Bazı doğa olaylarının ve canlı davranışlarının olağan dışı değişimlerden faydalanarak, depremi önceden kestirmeye yönelik çok başarılı bir yöntem ortaya konulamamıştır. Bugüne kadar yapılan çalışmalarda çoğunlukla depremi kestirme yolunda geçmişteki kayıtların stokastik değişimleri dikkate alınmıştır. Bu çalışmada, kayaç deformasyonu değişimiyle ilişkili deprem öncesi elektrik alan örüntülerinde görülen olağan dışı değişimlerin saptanması konusunda özgün bir deneysel çalışma yapılmıştır.

Kayaç deformasyonu sonucu oluşan elektrik alan ölçüm değerleri içinde deprem ile ilişkilendirilen özel bir örüntünün varlığı saptanmıştır. Bu çalışmada da depremle ilgili bu değişimin saptanması hedeflenmiştir.

Depremle ilgili bu örüntünün saptanmasında yapay sinir ağı yönteminden yararlanılmış ve bu yöntemin öğrenme ve tanıma gibi temel özellikleri örüntünün saptanması çalışmalarına uyarlanmıştır.

Tablo 1. Uygulamaların eğitim aşamasındaki ölçütleri ve başarımları

Uygulama	Parametreler	Başarım Değişimi
1	$\eta_1=0.4$ $\eta_2=0.2$ $\eta_3=0.1$ $\alpha=0.5$ $e=0.1$ $y=0.0999817$ $n=354$ $giris_ns=200$ $k1_ns=200$ $k2_ns=10$ $\text{çıkış_ns}=2$	
2	$\eta_1=0.6$ $\eta_2=0.4$ $\eta_3=0.2$ $\alpha=0.9$ $e=0.1$ $y=0.099845$ $n=74$ $giris_ns=200$ $k1_ns=200$ $k2_ns=10$ $\text{çıkış_ns}=2$	
3	$\eta_1=0.7$ $\eta_2=0.5$ $\eta_3=0.3$ $\alpha=0.9$ $e=0.04$ $y=0.0399$ $n=1002$ $giris_ns=200$ $k1_ns=200$ $k2_ns=10$ $\text{çıkış_ns}=2$	

Tablo 2. Deprem habercisi örüntüsünün saptanmasında ağıın deneme sonuçları

Olmaması beklenen	Örüntü	Uygulama					
		1	2	3	4	5	6
Deprem habercisi olan örüntü kodu [1 0]	1	0.3945	0.5848	0.4953	0.4523	0.9245	0.1154
	2	0.9468	0.0500	0.8728	0.0902	0.9821	0.0265
	3	0.9419	0.0567	0.9513	0.0394	0.9749	0.0354
	4	0.9263	0.0720	0.8034	0.1302	0.9125	0.0870
	5	0.9669	0.0337	0.9553	0.0429	0.9777	0.0267
	6	0.9609	0.0412	0.9454	0.0566	0.9790	0.0287
	7	0.9352	0.0638	0.9357	0.0654	0.9611	0.0375
	8	0.8784	0.1301	0.7269	0.3624	0.9149	0.0720
	9	0.0438	0.9592	0.0558	0.9609	0.0171	0.9847
	10	0.9634	0.0381	0.9481	0.0609	0.9723	0.0355
Olağan değişimi içeren örüntü kodu [0 1]	11	0.0661	0.9292	0.0505	0.9544	0.0447	0.9544
	12	0.0827	0.9147	0.1042	0.8990	0.1180	0.8957
	13	0.0944	0.8967	0.0593	0.9394	0.0453	0.9470
	14	0.0588	0.9457	0.0549	0.9524	0.0201	0.9808
	15	0.0377	0.9654	0.0489	0.9574	0.0148	0.9861

Çalışma kapsamında yapılan uygulamalar sonucunda şu noktalara ulaşılmıştır:

Kayaç deformasyonu sonucu oluşan elektriksel alanın ölçülmesi ve bu alanın içinde yer alan deprem habercisi örüntüsü yüksek bir olasılıkla saptanmıştır.

Yapılan çalışmada olağan dışı değişim örüntülerinin artmasıyla, öğrenmenin ilerlediği ve başarının arttığı belirlenmiştir.

Bu çalışmayla, Jeofizik dalına da verilerin işlenmesi açısından yeni bir bakış açısı kazandırılmıştır.

Semboller

- η_1 : Birinci gizli katman öğrenme katsayısı
 η_2 : İkinci gizli katman öğrenme katsayısı
 η_3 : Çıkış katman öğrenme katsayısı
 α : Momentum katsayısı
 e : Ortalama karesel hata
 y : Eğitimde yaklaşılan ortalama karesel hata
 n : Adım sayısı
 $giriş_ns$: Giriş nöron sayısı
 $k1_ns$: Birinci katmana ilişkin nöron sayısı
 $k2_ns$: İkinci katmana ilişkin nöron sayısı
 $çıkış_ns$: Çıkış katmanına ilişkin nöron sayısı

Kaynaklar

Buskirk, R. E., Frohlich, C., Latham, G. V. (1981). Unusual Animal Behavior Before Earthquakes: A

Review of Possible Sensory Mechanisms, Reviews Of Geophysics and Space Physics, **19**, 2, 247-270.

Canyaran L., Üstündağ B. (1999). Earthquake Forecast System, Turkish Patent Institute, Application no: 1999/02911.

Efe, M. Ö. ve Kaynak, O. (2000). Yapay Sinir Ağları ve Uygulamaları, Boğaziçi Üniversitesi
 Haykin, S. (1999). Neural Networks, A Comprehensive Foundation, Upper Saddle River, N.J. : Prentice Hall

Karlık B. (1994). Çok Fonksiyonlu Protezler için Yapay Sinir Ağları Kullanılarak Miyoelektrik Kontrol, Doktora Tezi, Yıldız Teknik Üniversitesi,
 Kohonen, T. (1980). Content Addressable Memories, Springer-Verlag, New York.

Matsuda, T., Yamanaka, C., Ikeya, M. (2001). Behavior of Stress-Induced Charges in Cement Containing Quartz Crystals, *phys. Stat. sol. (a)* **184**. 2.359-365.

Özerdem M. S., Sönmez C. ve Üstündağ, B., (2002). Anomali Örüntülerinin Yapay Sinir Ağlarıyla Öğrenilmesi ve Öngörüle Kullanımı, *10.Sinyal İşleme ve İletişim Uygulamaları (SİU2002)*, Pamukkale.

Reilinger, R., Barka, A. A. (1997). GPS constraints on slip rates in the Arabia-Africa-Eurasia plate collision zone: Implications for the earthquake recurrence times, *NATO ASI Serisi*. 28, 91-108.

Rojas, R. (1996). Neural Networks, A Systematic Introduction, Springer, Germany

Tiecheng W., Baoyin W. (1995). The Tidal Feature of Well Water Level and Its Anomalous

Depreme ilişkin olağan dışı sinyal değişimi

- Variations Before Earthquakes, Journal of Earthquake Prediction Research, **4**, 3.
- Yong S., Wai Z. (1995). The Correlation Between Radon Variation and Earth Solid Tide Change in Rock-Groundwater System-the Mechanical Foundation for Using Change to Predict Earthquake, Journal of Earthquake Prediction Research, **4**, 3.
- Zhonghao, S. (1999). Earthquake Clouds a Reliable Precursor, Science and Utopya 64, s.53-57
- Zurada, J. M. (1992). Introduction To Artificial Neural Networks, West Publishing Com.