

**ARTIFICIAL NEURAL NETWORK BASED PRINCIPAL COMPONENT ANALYSIS
METHOD FOR SEISMIC DATA ANALYSIS**

Ozan Arslan

Posta Adresi : KOÜ Veziroğlu Yerleşkesi, Mühendislik Fakültesi, KOCAELİ

E-posta : ozan601@yahoo.com

Anahtar Kelimeler: Sismik veri, yapay sinir ağı, öğrenme algoritması, ana bileşenler

ÖZ: Sismik veriler büyük boyutlara sahip hacimli veri gruplarıdır ve sismik yorumlamanın geliştirilmesi için orijinal veri grubu içinde bulunan bilgilerin çoğunu elde etmek isteriz. Büyük boyutlu veriler sözkonusu olduğunda çok değişkenli analiz tekniklerinin kullanılması gözlenen verilerin değerlendirilmesinde daha basit ve kolay yorumlanabilir sonuçlar elde etmemizi sağlar. Ana Bileşenler Analizi (ABA) yaygın olarak birçok uygulama alanında kullanılmaktadır (sismik veri kümelerine de uygulanmaktadır). Ancak mevcut ABA yöntemleri yüksek boyutlu, gürültü (bozucu etki) ve kayıp verilerin söz konusu olduğu durumlarda uygun olmayabilir. Parametrik olmayan yapısı ve gürültülü verileri işleyebilme kapasitesi nedeniyle Yapay Sinir Ağları (YSA), istatistik analiz problemlerinin çözümünde yeni bir seçenek olarak düşünülmektedir. Bu yüzden ABA yöntemi için bazı sinir ağı algoritmaları önerilmiştir. Bu çalışmanın amacı sismik veri analizinde mevcut ABA yönteminin geliştirilmesi amacıyla YSA kullanan etkin bir veri analiz yöntemi önermek ve bu yöntemi mevcut algoritmalarla karşılaştırmaktır.

ABSTRACT Seismic data always have a large data set with large dimension and we want to extract most of the information in the original set to improve the seismic interpretations. Considering the large amount of data with high dimensionality, employment of multivariate analysis techniques gives simpler and more easily interpretable results for the evaluation of observed data. The principal components analysis (PCA) has been widely used in many applications and applied to seismic data set as well. It can be viewed as a classical method of multivariate statistical analysis for achieving a dimensionality reduction. The PCA also provides a significant seismic data compression. However current PCA methods may not be appropriate for dealing with high-dimensional data, noisy data, and missing data. Due to their unique advantages of a non-parametric nature and ability to handle noisy data artificial neural networks (ANN) have been considered as a new alternative to overcome the statistical analysis problems. Therefore some neural networks algorithms have been proposed for principal components analysis (PCA). The objective of this paper is propose an effective data analysis methodology using an ANN and compare with the existing algorithms to improve current PCA methods in seismic data analysis.

GİRİŞ

Genel olarak çok boyutlu ve yüksek hacimli olan sismik verilerin analiz ve yorumlanması için çok değişkenli istatistik analiz tekniklerinden yararlanılmaktadır. Çokbileşenli sismik verilerin işlenmesi ve analizinde, ana bileşenler analizi (ABA) genellikle boyut indirgeme (azaltma) ve sınıflandırma amaçları için kullanılmaktadır (Guitierrez, 2000; Hagen, 1982; Savage, 1995). Sismik olarak aktif olan bölgelerde ölçülen jeoelektrik sinyallerin (depremle ilgili gerilim değişimleri vb. belirlenmesi için) analizinde, çokbileşenli sismik veri işleme ve filtrelemede, sismik özelliklerin (attribute) istatistik analizinde ve sismik örüntü tanıma yöntemi olarak bu yöntemden yararlanılmaktadır.

Sismik veriler genelde gürültü (bozucu etki) taşır ve bilinmeyen sismik dalgacıkların varlığı yüzünden karmaşık bir yapıya sahiptirler. Yüksek (hacimli) verileri içeren, bozucu etkilere sahip ve kayıp verilerin oluşabildiği bu tür problemlerde ABA en uygun çözüm

sağlamayabilir. Bu tür istatistik analiz problemlerinin çözümünde Yapay Sinir Ağları (YSA), çokdeğişkenli istatistik analiz tekniklerine bir alternatif olarak düşünülebilir (Bishop, 1995; Haykin, 1984). YSA örüntü tanıma, kestirim, işlem kontrolü ve sınıflandırma gibi birbirinden farklı birçok uygulama alanında başarıyla uygulanan, doğrusal olmayan hesaplama modeli sistemleridir. YSA'nın doğrusal olmayan fonksiyon yaklaşımı, veri sınıflandırması, non-parametrik regresyon ve karar süreçlerindeki yetenekleri; veri dağılımlarına ilişkin öncül bilgilerin olmadığı uygulamalarda çok önemlidir. YSA'nın, eksik veya gürültülü verilere sahip karmaşık problemlerin çözümündeki etkinliği kanıtlanmıştır YSA genel jeofizik uygulamalarda (dalga şekli tanıma, sismik tersinme, kuyu-kayıt analizi, iz düzeltme/düzenleme, sismik dekonvolüsyon) sıklıkla kullanılan bir yöntemdir (Dowla, 1990; Roth, 1994; Poulton, 1992; Huang, 1996, Calderon, 1997; Baan, 2000). Öte yandan YSA topluluğu içinde ABA algoritmasından yararlanılan sinir ağı modelleri de mevcuttur.

Bir sismik olayın doğasında "tahmin edilemezlik" olduğu söylenir ve gerçek veriler üzerinde hassas kestirim yapmayı zorlaştıran birçok etken vardır. Bunlar arasında, zayıf sinyal- görüntü oranı, başka kaynak ve aktivitelerden oluşan gürültüler, sinyallerin ortam içinde gezinirken saçılma nedeniyle oluşan büyüklük ve fazındaki değişimler,..vb. sayılabilir. Bu yüzden sismik olayların tanınmasında doğrusal olmayan kestirim yöntemleri tercih edilebilmektedir.

ANA BİLEŞENLER ANALİZİ (ABA)

Çok değişkenli istatistik analiz yöntemleri iki veya daha çok boyutlu rastlantısal değişkenleri bir bütün olarak ele alan ve değişkenler arasındaki ilişkileri göz önünde bulundurarak bütüncül bir sonuç üreten istatistiksel tekniklerden meydana gelmektedir. Bu istatistiksel tekniklere örnek olarak korelasyon ve regresyon analizi verilebilir. Bununla birlikte, çok değişkenli verilerin analizinde, bütüncül istatistiksel sonuçlar üretmenin yanısıra, çok değişkenli veri kümesinin yapısını tanımlamaya yönelik veri analiz teknikleri de vardır. Faktör analizi, gruplandırma (clustering) analizi, diskriminant analizi ve ana bileşenler analizi bu tür analiz teknikleridir.

ABA yöntemi bir değişken kümesini, değişkenlerin orijinal grubu içindeki bilginin çoğunu temsil eden daha küçük boyutta korelasyonsuz veri kümesine doğrusal olarak dönüştüren bir istatistik analiz tekniğidir. (Hotelling veya Karhunen-Loève dönüşümü olarak da bilinir.) Aralarında yüksek korelasyon bulunan çok değişkenli verileri aralarında korelasyon olmayan yeni bir sisteme doğrusal olarak dönüştürerek, dönüşüm sonrası veriler arasındaki korelasyon ortadan kaldırılmaktadır. Küçük boyutlardaki korelasyonsuz veri kümesinin yorumlanması çok daha kolay olduğu için bu veri "sıkıştırma" yöntemi yaygın olarak birçok uygulama alanında (mühendislik, tıp, biyoloji, kimya, meteoroloji, jeoloji,..vb) kullanılmaktadır. ABA yönteminin farklı nitelikte problemler için geliştirilmiş versiyonları (bağımsız bileşenler analizi, ana bileşen regresyon analizi, kompleks bileşenler analizi ..vb.) olduğu da bilinmektedir.

Çokdeğişkenli giriş veri setini $X = [x_1, \dots, x_N] = \begin{bmatrix} x_{11} & \dots & x_{1N} \\ \dots & \dots & \dots \\ x_{M1} & \dots & x_{MN} \end{bmatrix}$ şeklinde tanımlarsak;

sözgelişi N: sismik örnekleri ve M : giriş özellik sayısını temsil eder. Buradaki yaklaşım ; X giriş matrisini doğrusal olarak yeni bir C matrisine dönüştürecek şekilde bir U dönüşüm matrisi tasarlamaktır.

$$C = U^T X$$

Burada C ana bileşen matrisidir ve

$$C = [c_1 \dots c_N] = \begin{bmatrix} c_{11} & \dots & c_{1N} \\ \dots & \dots & \dots \\ c_{M1} & \dots & c_{MN} \end{bmatrix} = Q^T = \begin{bmatrix} q_1^T \\ \dots \\ q_M^T \end{bmatrix} = \begin{bmatrix} q_{11} & \dots & q_{N1} \\ \dots & \dots & \dots \\ q_{1M} & \dots & q_{NM} \end{bmatrix}$$

Bu eşitlikte C matrisinin evriğine farklı bir isim (Q) verilmesinin nedeni C ile giriş matrisi (X) arasındaki bire-bir ilişkiyi göstermek içindir. c_j vektörlerini, x_j örnek verilerinin dönüşmüş biçimi olarak ve q_i vektörlerini ise ana bileşenler olarak görebiliriz. U dönüşüm matrisi

$$U = [u_1 \dots u_M] = \begin{bmatrix} u_{11} & \dots & u_{1M} \\ \dots & \dots & \dots \\ u_{M1} & \dots & u_{MM} \end{bmatrix} \text{ olarak yazılır. Bu matrisin optimum değerlerini bulmak}$$

için q_i vektörlerini aşağıdaki biçimde yazabiliriz.

$$\begin{aligned} q_1^T &= u_1^T X \\ \dots & \dots \dots \\ q_M^T &= u_M^T X \end{aligned}$$

Böylece dönüştürülmüş özellik vektörleri elde edilmiş olur. q_i vektörünün varyansı,

$$\sigma_i^2 = u_i^T \Sigma u_i$$

ve q_i ile q_k vektörlerinin kovaryansı ,

$$\sigma_{ik} = u_i^T \Sigma u_k$$

biçiminde yazılabilir. Burada Σ :kovaryans matrisini göstermektedir.

Buradan ana bileşenlerin her birinin (q_i) varyansını enbüyük yapan u_i vektörleri bulunur ve vektörlerin ortonormal (dik) olma koşuluyla kovaryans değerlerini -0- yapar. (Dönüşümden sonra eksenler arasında diklik koşulu korunacağından dönüşüm matrisi ortogonal olacaktır.) Bunu

$$u_i^T u_k = \delta_{ik} = \begin{cases} 1, i = k \\ 0, i \neq k \end{cases} \text{ biçiminde gösterebiliriz.}$$

Böylelikle en büyük yapılan varyanslar X matrisinin özdeğerlerine eşdeğer olur. İlk ana bileşen, enbüyük varyansa ilişkin özvektör kullanılarak hesaplanır ve bu biçimde devam ettirilir. Ana bileşen dönüşümü hesaplandığında boyut azaltma işlemi gerçekleşmiş olur. Kovaryans matrisi aşağıdaki biçimde yeniden yapılandırılabilir.

$$\Sigma = U \Lambda U^T$$

$$\Lambda = \begin{bmatrix} \lambda_1 & 0 & 0 \\ 0 & \dots & 0 \\ 0 & 0 & \lambda_M \end{bmatrix} \text{ ana köşegeni boyunca özdeğerleri içeren bir matristir.}$$

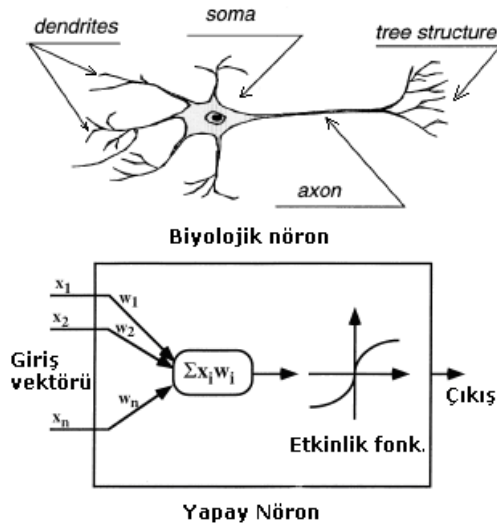
Dönüşümden sonra ana bileşenlerin varyanslarının büyüklüklerine göre sıralanabilmesi için, özdeğerler büyüklüklerine göre sıralanır.

Giriş verilerinin ana bileşenlerin altuzayına projeksiyonuna "yükleme" denilmektedir ve ana bileşenlerle orijinal veriler arasındaki korelasyonun derecesini gösterir. ABA' nın anlamlı indirgeme yapıp yapmadığı istatistik olarak da test edilebilir.

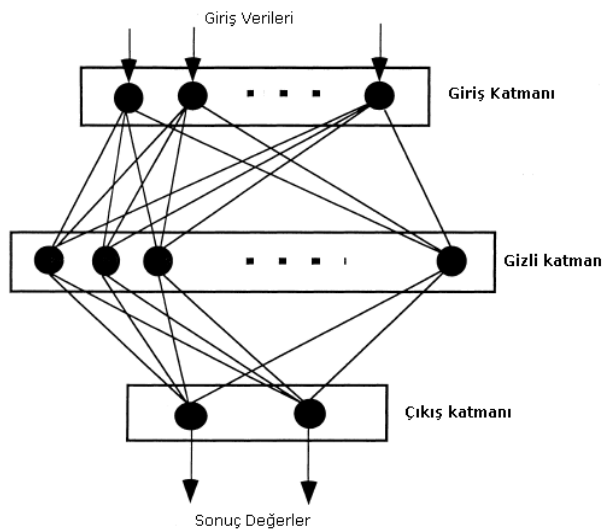
YAPAY SİNİR AĞLARI (YSA)

Çok boyutlu veri uzayında doğrusal olmayan verileri işleyebilme kapasitesine sahip Yapay Sinir Ağları parametrik olmayan yapısı nedeniyle çok çeşitli bilimsel disiplinlerde (fonksiyon tahmini, regresyon, örüntü tanıma, sınıflandırma, işlem kontrolü, robot teknolojisi, ...vb) başarıyla kullanılmaktadır. YSA, insan beyninin çalışma tarzına benzer biçimde, biyolojik nöron hücrelerinin yapısı ve öğrenme karakteristiklerinden esinlenerek geliştirilmiş, birlikte işleyen çok sayıda işleme elemanından oluşan bir bilgisayar işleme ve hesaplama sistemi olarak tanımlanabilir. (Haykin, 1994; Zurada, 1992) İnsan beyninin problem çözme, hatırlama, bilgi elde etme, vb. yeteneklerini modelleyebilmek için ileri hesaplama kapasitesine sahip yapay sistemler üretme isteği yapay sinir ağlarına esin kaynağı olmuştur. Parametrik olmayan yapısı, standart yöntemlere ilginç bir alternatif oluşturan "öğrenme" yeteneği, olasılık modeli ilgili herhangi bir varsayım yapmaması, özellik uzayında yüksek dereceden doğrusal olmayan "karar sınırları" oluşturabilme yeteneği, gürültü (noisy) verilerini işleyebilme ve farklı veri türlerine uyum yeteneği önemli özelliklerindedir (Richard, 1991). Olumsuz yönleri olarak; eğitim için uzun zaman gerektirmesi, probleme özgün ağ yapısının belirlenmesi gereği, başlangıç koşullarına bağlı olması ve 'verilere bağlı' bir model olması söylenebilir.

Bir sinir ağı her biri az miktarda lokal hafızaya sahip birçok işleme elemanından (nöron) oluşur; her bir nöronun giriş verisi ya dış uzaydan alınır ya da bu veriler diğer nöronların çıkış verisi olabilir. Bütün nöronların çıkış sinyalleri giderek etkisini tüm ağ boyunca gösterir ve sonuç katmana kadar yayar; sonuçları da gerçek dünyanın sonucu olur. Bir YSA giriş vektörünü aldığı anda çıkış vektörü formunda bir yanıt üretir. Giriş işleme elemanları çıkış birimlerine gizli elemanlarla bağlıdır. Gizli birimler (gizli katmanlar) giriş ve çıkış bilgileri arasındaki doğrusal olmayan ilişkileri temsil etmektedir. Şekil 3.1 de tek bir doğal ve yapay nöronun modeli ile şek. 3.2'de çok katmanlı YSA yapısı görülmektedir.




Şekil 3.1: Nöron modeli



Şekil 3.2: Çok katmanlı YSA yapısı

Sinir ağları katmanlar halinde organize edilirler. Bir YSA'da katmanları oluşturan işleme elemanlarının (nöron) yapısını incelemek gerekir. Herhangi bir sinir ağı içindeki her nöron Şekil 3.1 deki gibi modellenebilir. Burada nöronun giriş verileri (\mathbf{x}), ağırlıklandırılarak (\mathbf{w}) elde edilen toplam giriş bir etkinleştirme fonksiyonundan (f) geçirilerek nöronun çıkışı (sonuç) üretilmektedir. Genel olarak bir nöron birden fazla giriş değerine sahiptir.

Etkinleştirme fonksiyonu (transfer fonksiyonu) nöron ya da ağ sonucunu üretmekte ve şekillendirmektedir (Şekil 3.3).



Şekil 3.3: Genel etkinleştirme fonksiyonları

Sinir ağı kullanıcıları arasında en çok kullanılan etkinleştirme fonksiyonu sigmoid fonksiyondur ve giriş fonksiyonunun büyük değerlerini [0,1] aralığına 'sıkıştırılmaktadır'.

$$f(n) \approx \frac{1}{1 + e^{-n}}$$

Sinir ağları örneklerden "öğrenir" ve örnekleme verileri (eğitim seti) üzerinde genelleştirme yeteneğini kullanır. Genelleştirme, sinir ağının örnekleme veri seti içinde yer almayan yeni verileri kestirebilme yeteneğidir. Bir sinir ağının "gücü", örnekleme verilerinden ne kadar iyi genelleştirme yapabildiğine bağlıdır. Öğrenme algoritması; istenen (hedef) çıkış vektörü ile gerçekleşen çıkış vektörü arasındaki fark cinsinden bir ölçü değeri olan hata fonksiyonunu kullanarak; deneme (eğitim) seti üzerindeki ortalama hatayı azaltacak şekilde, ağ içindeki ağırlıkları dengelemektedir. Bu doğru olarak gerçekleştirildiğinde sinir ağı, yeni giriş verileri için istenen sonuçları doğru olarak tahmin edecektir (Hertz, 1991).


Genel olarak YSA kullanımı, tasarım ve uygulama sırasında karşılaşılan sorunlar nedeniyle karmaşık ve zaman alıcı bir süreçtir. Farklı nitelikteki problemler (veriler) için kurulacak ağ topolojisi (katman ve nöron sayısı, bağlantı ilişkileri) de aynı olmayacaktır. Tasarım açısından gizli katmanların sayısı ve büyüklüğünün (nöron sayısı) belirlenmesi, ağın "öğrenme" ve genelleştirme kapasitesini etkilediği için son derece önemlidir. Öğrenme algoritması bir YSA uygulamasının temel bileşeni olup çok sayıda öğrenme stratejisi (kontrollü, kontrolsüz ve zorlamalı) geliştirilmiştir. En çok kullanılan ve bilineni geriyayılma (backpropagation) olup, bazı sakıncaları bilinmektedir. Bir diğer önemli konu, öğrenme algoritmasının performansını etkileyen uygun parametre seçimi konusundadır. Geriyayılma algoritması için bu parametreler; başlangıç ağırlıklar dizisi (aralık), öğrenme oranı, momentum terimi, yineleme sayısı ve durdurma ölçütü parametreleridir. Doğal olarak farklı algoritmalar için bu parametreler de değişmektedir. Uygun parametrelerin belirlenmesi konusunda genelde bir "deneme-yanılma" stratejisinin uygulandığı söylenebilir. Eğitim (çalıştırma) esnasında bu parametreler dinamik olarak değiştirilebilir ve öğrenmenin sağlanıp sağlanmadığı sorgulanabilir. Ağ topolojisinin belirlenmesinde, farklı nitelikteki problemler için her zaman geçerli olabilecek nitelikte, tek ve en uygun bir mimari yoktur. Bu nedenle "probleme özgün" ağ mimarisi tasarlamak gerekir. Bununla birlikte belli kategorilerdeki problemler için hangi ağ yapısının seçilmesi gerektiği konusunda bazı ön bilgilere de sahibiz. (Sözgelisi tek gizli katmana sahip bir MLP ağı, yeterince eğitildiğinde hemen hemen her fonksiyona yaklaşabilir. Benzer biçimde gizli katmanı olmayan ileri beslemeli ağlar, genelleştirilmiş doğrusal modellere özdeştir. Genel olarak ileri beslemeli sinir ağlarını, doğrusal olmayan çok değişkenli regresyon modelleri ile ilişkilendirmek mümkündür..vb.) YSA diğer doğrusal olmayan modellerle karşılaştırıldığında, YSA'nın daha çok başlangıç koşullarına ve doğal olarak öğrenme sürecine bağlı olduğu söylenebilir. Bu nedenle eğitim aşamasında başlangıç ağırlıklarının seçimi de önemlidir. Bir YSA farklı ağırlık dizileri için çalıştırılıp uygun başlangıç değerleri belirlenmelidir. Bazı uygulamalar için başlangıçta veriler üzerinde bir ön işleme yapılması

(önışleme; kodlama, homojenleřtirme, normlandırma vb.) belirgin bir iyileřme sađlamaktadır.

YSA- ABA MODELİ

Aslında son yıllarda YSA, jeofizik ve jeoteknik uygulama alanlarında sıklıkla kullanılmaktadır. Bunlar arasında sismik sinyal işleme, sinyal sınıflandırma, gürültülü sismik verilerin düzeltilmesi, sismik ayırma (diskrimnasyon), sismik örüntü tanıma, çok bileşenli sismik veri filtreleme, sismik olayların otomatik olarak tanınması, kayıp sismik verilerin yeniden kazanılması, sismik görüntülerin veri sıkıştırması,..örnekleri sayılabilir.

ABA için YSA yaklaşımında kovaryans matrisinden ana özvektörlerin bulunması için genellikle kontrolsüz öğrenme algoritmaları (genellikle Hebbian, RBF,..vb) tercih edilmektedir(Sanger, 1989;Openshaw, 1996; Penn, 2005). ABA'nın YSA versiyonunda, ana bileşenler çevrimiçi olarak hesaplanır. Ana bileşenlerin "öğrenilmesi" için uygun bir öğrenme kuralı seçilmelidir. Aşağıda şematik olarak m giriş nöronlu ve tek çıkış nöronlu bir YSA yapısı gösterilmektedir.



Şekil 1. YSA-ABA Modeli

Giriş katmanındaki x_i verileri ağırlıklandırılarak (w_i), sonuç vektörü (y) elde edilmektedir.

$$y(t) = \sum_{i=1}^m w_i(t)x_i(t).$$

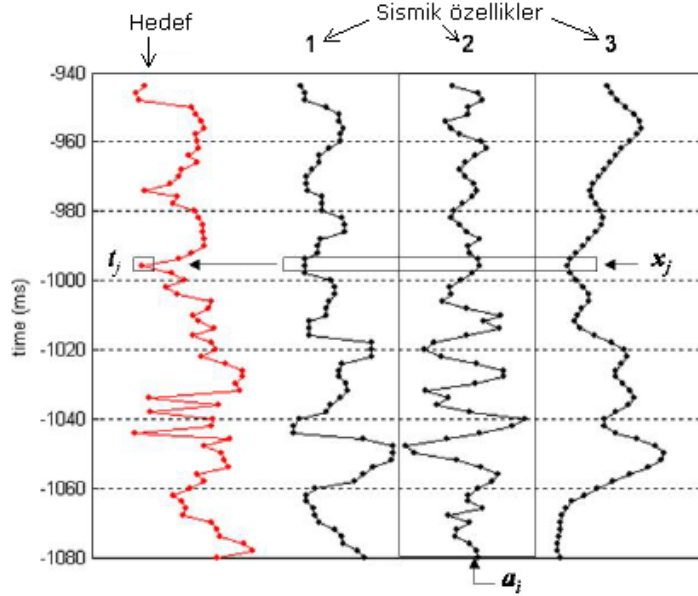
Ağırlıkların güncellenmesi problemin yapısına uygun olarak seçilen bir YSA öğrenme kuralına göre yapılır. Hebb öğrenme kuralı genel olarak bu tür problemler için uygun bir kontrolsüz öğrenme algoritmasıdır. Bu kurala göre hem giriş hem de çıkış nöronu aynı anda etkinlik gösterirse, bu iki nöron arasındaki ağırlık artırılmalıdır. Başka bir deyişle,

$$w_i(t_{j+1}) = w_i(t_j) + \eta y(t_j) x_i(t_j)$$

yazılabilir, burada η küçük bir skalar değerdir. Algoritmanın bu biçimi yakınsamayan özelliğindedir, bu nedenle ağırlıklar için bir normalleştirme terimi kullanılır.

$$w_i(t_{j+1}) = \frac{w_i(t_j) + \eta y(t_j) x_i(t_j)}{[\sum_{i=1}^m (w_i(t_j) + \eta y(t_j) x_i(t_j))]^{\frac{1}{2}}}.$$

İlgi çekici nokta buradadır :Hebb'in bu öğrenme kuralının veri kümesinin ilk ana bileşenini hesapladığı kanıtlanmıştır(Oja, 1982). (Yani $y(t)$ ilk ana bileşene yakınsar.) YSA-ABA yöntemi tek bir ağ olarak eğitilir fakat kavramsal olarak iki ağ yapısı olarak ele alınabilir. İlk ağ veri vektörlerini ana bileşenlere dönüştürürken diğeri bu bileşenleri orijinal veri boyutuna genişleterek ağ sonuçlarını üretmektedir.



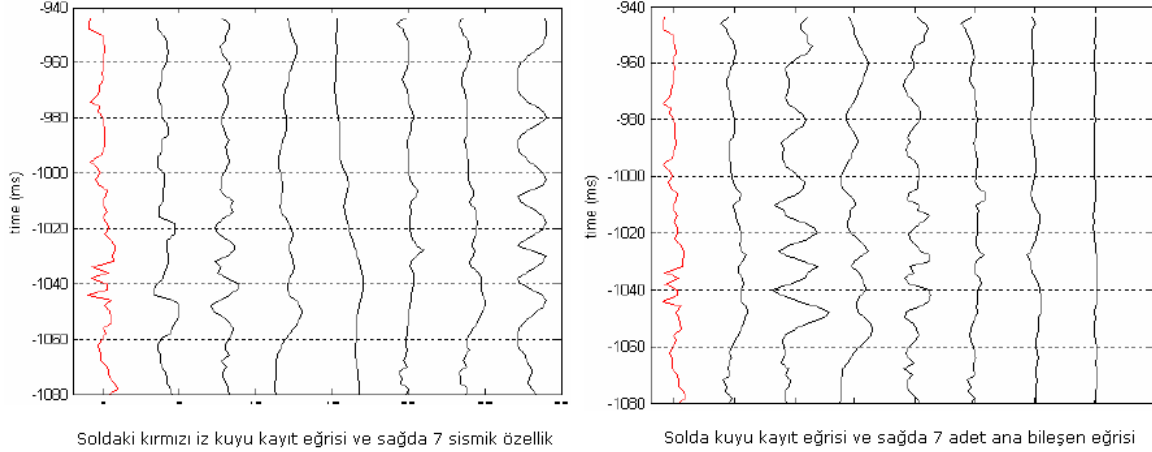
Şekil 4.3. Hedef havza kayıt grafiği

Bu grafikte solda (kırmızı) hedef P-dalgası sonik kayıt ve sağda 3 adet sismik özellik (1.tersinmiş sismik direşim, 2.sismik izin zamana göre türevi, 3.izin zamanla integrasyonu) gösterilmektedir. Noktalar sismik özelliklere ilişkin zaman örneklerini temsil etmektedir. Hedef kayıt ile sismik özelliklere ait özet istatistik değerler Tablo.1'de verilmektedir. Şekilde tek bir örnek gösterilmektedir; kutu içindeki sismik özellikleri içeren noktalar M boyutlu x_j vektörünü oluşturur ($M=3$). Hedef kaydı içeren kutu içindeki nokta ise t_j skalar değerdir. a_i ise özellik vektörüdür. ($x_j = a_i^T$) Penceredeki N adet örnek ($N=69$) için özellik vektörlerinden hedef değeri (bir havza parametresi) hesaplanabilmelidir. Genel anlamda problem; belirli kuyu konumlarında bir havza parametresi ile sismik özellikler grubu arasındaki ilişkinin belirlenmesi ve hedef kaydı kestirebilmek için sismik özelliklerin optimum biçimde kombine edilmesi üzerinedir.

Tablo 1. Değişkenlerin istatistik özeti

	Ortalama	varyans	standart sapma
Hedef	3975 m/s	$1.303 \times 10^5 \text{ (m/s)}^2$	361 m/s
1. özellik	9903 m/s·g/cc	1.709×10^6	1307 m/s·g/cc
2. özellik	15.3	7.875×10^3	887
3. özellik	264	4.187×10^7	6471

YSA-ABA modelini benzer bir örnek bir veriseti üzerinde uygulamak üzere yukarıda açıklanan yaklaşım kullanılacaktır. Burada tek fark; şekilde 3 yerine 7 adet sismik özelliğin yer almasıdır. Şekil 4.4'te solda kestirilecek bir kuyu kayıt eğrisi ve sağda 7 adet sismik özellik gösterilmektedir.



Şekil 4.4. Uygulama örneği için seçilen kuyu kayıtları

Seçilen örnek için YSA-ABA modeliyle hesaplanan özdeğer ve özvektörlerden yararlanarak önceki bölümlerde kullanılan notasyona da uygun olarak aşağıdaki sonuç değerler (matris formunda) elde edilmiştir.

$$A = \begin{bmatrix} 1.0000 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0.4478 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0.2255 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0.1553 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0.0537 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0.0262 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0.0027 \end{bmatrix}$$

Ana Bileşenler

	AB1	AB2	AB3	AB4	AB5	AB6	AB7
1. özellik	0.5004	-0.0451	-0.1324	-0.1233	-0.6533	-0.4930	-0.2120
2. özellik	-0.0178	-0.6306	0.2408	0.7178	-0.0330	-0.1659	0.0120
3. özellik	0.1188	0.4771	0.8220	0.1054	0.0759	-0.2038	-0.1557
4. özellik	0.5011	-0.0974	-0.1624	-0.0817	0.7288	-0.4131	0.0672
5. özellik	0.4889	-0.0415	-0.0281	0.1425	0.0756	0.6238	-0.5859
6. özellik	0.4944	0.0772	0.1153	0.0988	-0.1715	0.3381	0.7635
7. özellik	-0.0242	0.5962	-0.4565	0.6494	0.0014	-0.1175	-0.0074

Özdeğerler büyükten küçüğe doğru sıralanmış ve enbüyük özdeğer 1 olacak şekilde ölçeklendirilmiştir. Şekil 4.4'te ana bileşenler soldan sağa büyükten küçüğe doğru sıralanmıştır. Sonuçta en soldaki kuyu kayıt eğrisini yeniden inşa etmek için bu ana bileşenlerin altkütmesi (sismik özellikler) kullanılabilir.

YSA-ABA modeli sonuçları ile standart ABA yöntemi ile bu örnek için elde edilen sonuç değerleri karşılaştırıldığında aynı ana bileşenlerin hesaplandığı görülmüştür. Ancak

dönüşüm matrisleri incelendiğinde ise YSA-ABA modelinin sonuç değerlerinde belirgin bir gelişme görülmüştür. Bununla birlikte her iki model (standart ABA ve YSA-ABA) ile diğer çok değişkenli analiz teknikleri, ilerdeki çalışmalarda yüksek hacimli sismik veriler üzerinde de çalıştırılarak elde edilecek sonuçlar tartışılmalıdır.

SONUÇ

YSA-ABA modelinin, sismik veri analizinde kullanılmakta olan çokdeğişkenli istatistik analiz yöntemlerine alternatif olarak kullanılabilmesi gösterilmiştir. Bu çalışma klasik ABA yöntemine yapay sinir ağlarının katkısı veya ABA algoritmasının geliştirilmesi anlamında da değerlendirilebilir. YSA-ABA modeli bilinen standart ABA yöntemine göre aynı ana bileşenleri üretmesine rağmen sonuç değerlerde belirgin bir iyileşme sağlamıştır. Bu yöntemin yüksek hacimli veriler üzerindeki kullanımının ek yararlar sağlayacağı öngörülmektedir. Ayrıca YSA-ABA modelini ile diğer çokdeğişkenli istatistik analiz yöntemleriyle karşılaştırmak ilginç olacaktır.

KAYNAKLAR

- Baan, M., Jutten, C., 2000, Neural networks in geophysical applications, **Geophysics**, 65(4), 1032-1047.
- Bishop, C.M. , 1995, Neural Networks for Pattern Recognition, Oxford University Press.
- Calderon-Macias, C., Sen, M. K., and Stoffa, P. L., 1997, Hopfield neural networks, and mean field annealing for seismic deconvolution and multiple attenuation, **Geophysics**, 62, 992-1002.
- Dowla, F. U., S. R. Taylor, and R. W. Anderson, 1990. Seismic Discrimination with Artificial Neural Networks: Preliminary Results with Regional Spectral Data, **Bull. Seism. Soc. Am.** 80, 1346-1373.
- Haykin, S., 1994, Neural networks: A comprehensive foundation. Upper Saddle River, NJ: Prentice Hall.
- Hagen, D. C., 1982, The application of principal components analysis to seismic data sets, **Geoexploration**, 20, 93-111.
- Hertz J., Krogh A. and Palmer, R., 1991, Introduction to the Theory of Neural Networks, Addison Wesley.
- Huang, Z., Shimeld, J., Williamson, M., and Katsube, J., 1996, Permeability prediction with artificial neural network modeling in the Ventura gas field, offshore eastern Canada, **Geophysics**, 61, 422-436.
- Gutierrez E, Zaldivar J.M., 2000, The application of Karhunen-Loeve, or principal component analysis method, to study the non-linear seismic response of structures. **Earthquake Engineering and Structural Dynamics**, 29:1261-86.
- Oja, Erkki., 1982, A Simplified Neuron Model as a Principal Component Analyzer. **Journal of Mathematical Biology**, 15: 267-273.
- Openshaw, S. and Turton, I. 1996, A parallel Kohonen algorithm for the classification of large spatial datasets, **Computers and Geosciences**, 22(9), 1019-1026.
- Penn, B. S., 2005, Using self-organizing maps to visualize highdimensional data, **Computers and Geosciences**, 31(5), 531-544.

Poulton, M. M., Sternberg, B. K., and Glass, C. E., 1992, Location of subsurface targets in geophysical data using neural networks, **Geophys.**,57(12), 1534-1544.

Roth, G., and Tarantola, A., 1994, Neural networks and inversion of seismic data: **J. Geophys. Res.**, 99, 6753-6768.

Russell, B. H.,2004, The application of multivariate statistics and neural networks to the prediction of reservoir parameters using seismic attributes, PhD. Thesis, University of Calgary.

Savage, J.C., 1995, Principal component analysis of interseismic deformation in outhern California. **J. Geophys. Res.** ,100,12691-12701.

Sanger, T.D., 1989, Optimal unsupervised learning in a single layer linear feedforward neural network, **Neural Networks**, 2, 459-473.

Sanger, T. D., 1989, An optimality principle for unsupervised learning, **Advances in Neural Information Processing Systems**, 1, 11-19.