

DOKUZ EYLÜL ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

BATI TÜRKİYE GRAVİTE VE DEPREM
KATALOG VERİLERİNİN YAPAY SİNİR
AĞLARI İLE DEĞERLENDİRİLMESİ

İlknur KAFTAN

Şubat, 2010
İZMİR

**BATI TÜRKiYE GRAVİTE VE DEPREM
KATALOG VERİLERİNİN YAPAY SİNİR
AĞLARI İLE DEĞERLENDİRİLMESİ**

Dokuz Eylül Üniversitesi Fen Bilimleri Enstitüsü

Doktora Tezi

Jeofizik Mühendisliği Bölümü, Jeofizik Mühendisliği Anabilim Dalı

İlknur KAFTAN

Şubat, 2010

İZMİR

DOKTORA TEZİ SINAV SONUÇ FORMU

İLKNUR KAFTAN tarafından PROF.DR. MÜJGAN ŞALK yönetiminde hazırlanan “BATI TÜRKİYE GRAVİTE VE DEPREM KATALOG VERİLERİNİN YAPAY SİNİR AĞLARI İLE DEĞERLENDİRİLMESİ” başlıklı tez tarafımızdan okunmuş, kapsamı ve niteliği açısından bir doktora tezi olarak kabul edilmiştir.

Prof. Dr. Müjgan ŞALK

Danışman

Prof. Dr. Coşkun SARI

Tez İzleme Komitesi Üyesi

Prof. Dr. Cüneyt GÜZELİŞ

Tez İzleme Komitesi Üyesi

Prof. Dr. Mustafa ERGÜN

Jüri Üyesi

Prof. Dr. Zuhal DÜZGİT

Jüri Üyesi

Prof.Dr. Cahit HELVACI

Müdür

Fen Bilimleri Enstitüsü

TEŞEKKÜR

Doktora çalışmamı öneren ve çalışmalarım boyunca desteğini esirgemeyen hocam Sayın Prof.Dr. Müjgan ŞALK'a teşekkürlerimi sunarım.

Tez çalışmamın tüm aşamalarında karşılaştığım sorunlarda her an danışabildiğim ve değerli görüşleriyle tezime katkıda bulunan tez izleme komitesi üyelerim Sayın Prof.Dr. Coşkun SARI ve Sayın Prof.Dr. Cüneyt GÜZELİŞ'e destekleri için teşekkür ederim.

Çalışmanın çeşitli aşamalarında bilgi ve desteğini gördüğüm Elektrik ve Elektronik Mühendisliği öğretim üyesi Sayın Yrd. Doç. Dr. Yavuz ŞENOL'a, destekleri ile bana güç veren bölümümüz öğretim elemanları sevgili Öğr. Gör. Dr. Özer AKDEMİR, Öğr. Gör. Dr. Petek SINDIRGI, Öğr. Gör. Dr. Oya Pamukçu ve Öğr. Gör. Mehmet TARAKÇI'ya teşekkür ederim.

Hayatımın her aşamasında yanımda olan, tüm kararlarımda bana inanan ve destek olan sevgili anne ve babam Nesrin-Ahmet KAFTAN'a , kardeşim Öznur KAFTAN'a teşekkür ve şükranlarımı sunarım.

İlknur KAFTAN

BATI TÜRKİYE GRAVİTE VE DEPREM KATALOG VERİLERİNİN YAPAY SINIR AĞLARI İLE DEĞERLENDİRİLMESİ

ÖZ

Son yıllarda Yapay Sinir Ağları (YSA) bilim ve mühendislikteki çeşitli problemlerin çözümünde yaygın olarak kullanılmaktadır. Jeofizik alanındaki uygulamaları da giderek artmaktadır. Özellikle sismik, elektromanyetik ve öz direnç gibi yöntemlerin ters çözümünde uygulanmaktadır. Ayrıca parametre tayini, önkestirim ve sınıflama gibi uygulamalarda da kullanılmaktadır.

Bu çalışmada Yapay Sinir Ağlarının iki farklı türü olan Çok Katmanlı Algılayıcı (ÇKA) ve Radyal Taban Fonksiyonlu Ağlar (RTFA) kullanılmıştır. Bu yöntemler gravitede önce kuramsal modellere, daha sonra Batı Türkiye verilerine uygulanmıştır. Bölgedeki önemli tektonik unsurlar olan Gediz ve Büyük Menderes grabenlerinin tortul kalınlığının ve bölgenin kabuk kalınlığının bulunması amaçlanmıştır. Öğretmenli öğrenme temeline dayanan ÇKA ve RTFA, farklı gravite modelleri içeren eğitim setini kullanarak mevcut modellerin giriş çıkış ilişkilerini öğrenmekte ve benzer modeller için genelleme yöntemiyle çözümler üretebilmektedir. Böylece gravite yöntemindeki çok çözümlülük sorununa farklı bir bakış açısı getirmektedir.

Gediz grabeni için tortul kalınlığının Salihli civarı için 1,4 – 2 km, Alaşehir civarı için yaklaşık 2,5 km olduğu saptanmıştır. Büyük Menderes grabeninin tortul kalınlığı ise Aydın civarı için yaklaşık 1,7 km, Nazilli civarı için yaklaşık 2,2 km, Sarayköy civarı için ise yaklaşık 3,2 km olarak saptanmıştır. Bölgenin ortalama kabuk kalınlığı ise yaklaşık 32 km olarak elde edilmiştir.

Gravite çalışmalarına ek olarak Yapay Sinir Ağlarının zaman serilerindeki performansını test etmek amacıyla sismoloji katalog verilerine uygulanmıştır. Batı Türkiye deprem oluş aylık frekansları hesaplanmış, ÇKA ve RTFA ile değerlendirilmiş ve ön kestirim çalışmaları yapılmıştır. Frekans verileri 1, 2, 3, 4, 5,

6, 7, 8, 9, 10 ve 11 li girdi setleri olacak şekilde düzenlenmiş ve her iki yöntemle değerlendirilmiştir. Elde edilen sonuçlar incelendiğinde RTFA ile elde edilen ön kestirim sonuçlarının ÇKA sonuçlarına göre daha yüksek korelasyon katsayısı ve daha düşük hata değerlerine sahip olduğu gözlenmiştir.

Anahtar sözcükler: Yapay Sinir Ağları, Çok katmanlı Algılayıcı, Radyal Taban Fonksiyonlu Ağlar, Gravite yöntemi, Deprem frekans ön kestirimi

INTERPRETATION OF GRAVITY AND EARTHQUAKE CATALOG DATA IN WESTERN TURKEY BY USING ARTIFICIAL NEURAL NETWORKS

ABSTRACT

Artificial Neural Networks (ANN) has been used in a variety of problems in the fields of science and engineering. Applications of ANN to the geophysical problems have increased within the last decade. In particular, it has been used to solve inversion problems such as seismic, electromagnetic and resistivity. Also, there are some other applications such as parameter estimation, prediction and classification.

In this study, two different types of ANN, Feed Forward Neural Networks (FNN) and Radial Basis Function Networks (RBF NN) were used. These methods were applied first to synthetic gravity data and then to the Western Turkey Bouguer gravity data. The aim of the study was to obtain sediment thickness of the major structure of the regional tectonics such as the grabens of Gediz and Büyük Menderes and the crustal thickness of the region. ANN can learn input-output relation of available models by using training set, which includes various gravity models, and produce solutions for similar models via its generalization ability. Therefore ANN can provide a different perspective for the multi solution problem in gravity method.

The sediment thickness of the Gediz graben was determined as 1,4- 2 km around Salihli and about 2,5 km around Alaşehir. The sediment thickness of the Büyük Menderes was determined approximately 1,7 km around Aydın and 2,2 km around Nazilli and 3,2 km around Sarayköy. Average crustal thickness was obtained as 32 km for the region.

In addition to the gravity studies ANN was also applied to seismological catalog data in order to test of the performance. Monthly earthquake frequencies were calculated using seismological catalogue data of the region and then the data set were evaluated with these FNN and RBF NN methods for earthquake prediction purposes. Frequency data were arranged as 1, 2, 3, 4, 5, 6, 7, 8, 9, 10, and 11 input sets and

evaluated by using these two methods. When the results of two methods were compared, it was observed that the preliminary prediction results by using RBF NN, gave a greater correlation coefficient and less error values than MLP.

Keywords: Artificial Neural Networks, Multilayer Perceptron, Radial Basis Function Networks, Gravity Method, Prediction of Earthquake Frequency

İÇİNDEKİLER

	Sayfa
DOKTORA TEZİ SINAV SONUÇ FORMU	ii
TEŞEKKÜR.....	iii
ÖZ	iv
ABSTRACT.....	vi
BÖLÜM BİR – GİRİŞ	1
1.1 Yapay Zeka ve Yapay Sinir Ağları tanımı.....	3
1.1.1 Yapay Sinir Ağlarının tarihçesi.....	4
1.1.2 Biyolojik Sinir Sistemi.....	5
1.2 Yapay Sinir Ağı ve Temel Elemanları	7
1.3 Yapay Sinir Ağlarının Sınıflandırılması	11
1.3.1 Yapılarına Göre Ağlar.....	12
1.3.1.1 İleri Beslemeli Ağlar	12
1.3.1.2 Geri Beslemeli Ağlar.....	12
1.3.2 Öğrenme Algoritmalarına Göre Ağlar	13
1.3.2.1 Öğretmenli Öğrenme (Supervised Learning).....	13
1.3.2.2 Öğretmensiz Öğrenme (Unsupervised Learning)	14
1.3.2.3 Takviyeli Öğrenme (Reinforcement Learning).....	15
1.3.3 Öğrenme Kuralları	15
1.3.3.1 Hebb Kuralı.....	16
1.3.3.2 Delta Bar Delta Kuralı	16
1.3.4 Yapay Sinir Ağlarının Avantaj ve Dezavantajları	16
1.3.4.1 Avantajları.....	16
1.3.4.2 Dezavantajları	17
1.4 Yapay Sinir Ağlarının Jeofizikteki Uygulamaları.....	17
BÖLÜM İKİ - KULLANILAN YÖNTEMLER	21
2.1 Çok Katmanlı Algılayıcı (Multilayer Perceptron)	21

2.1.1 Geri Yayılım Algoritması (Backpropagation Algorithm).....	22
2.2.1.1 Öğrenme ve Momentum katsayıları.....	27
2.2 Radyal Taban Fonksiyonlu Ağlar (RTFA).....	29
2.3 ÇKA ve RTFA Arasındaki Farklar.....	30
BÖLÜM ÜÇ – UYGULAMALAR	32
3.1. Gravite Verilerinin Yapay Sinir Ağları ile Değerlendirilmesi.....	32
3.1.1 Kuramsal Modeller.....	34
3.1.1.1 Nokta Kütle ve Küre	35
3.1.1.2 Nokta Kütle ve Küre Anomalisi Üzerinde Random Gürültünün Etkisi.....	36
3.1.1.3 İki Boyutlu Kuramsal Modeller	38
3.1.1.3.1 Graben Modeli	39
3.1.1.3.2 Dayk Modeli	40
3.1.1.3.3 Basamak Modeli	42
3.1.1.4 Kuramsal İki Farklı Yapıdan Oluşan Modeller.....	43
3.1.1.5 Kuramsal İki Farklı Yapıdan Oluşan Modellerde Gürültünün Etkisi	44
3.1.2 YSA' nın Jeofizik Verilere Uygulanması	47
3.1.2.1 Batı Türkiye'nin Tektoniği	47
3.1.2.2 Batı Türkiye Gravite Verileri.....	51
3.1.2.3 Gediz Grabeni	52
3.1.2.4 Büyük Menderes Grabeni	60
3.1.2.5 Seferihisar Jeotermal Bölgesi.....	65
3.1.2.6 Batı Anadolu'nun Kabuk Kalınlığının Saptanması.....	68
3.1.2.7 Batı Anadolu Deprem Frekanslarının YSA ile değerlendirilmesi	69
BÖLÜM DÖRT - SONUÇLAR	77
KAYNAKLAR	80

BÖLÜM BİR

GİRİŞ

Yapay sinir ağları teknolojinin de etkisiyle son yıllarda bir çok problemin çözümünde yaygın olarak kullanılan yöntemlerden biri olmuştur. Uygulama alanının geniş olması ve birçok problemin çözümünde başarılı sonuçların elde edilmesi bu yönetime olan ilgiyi arttırmıştır.

Son yıllarda yer bilimlerinde de uygulanan yöntem birçok problemin çözümünde farklı bakış açılarının oluşmasına neden olmuştur. Özellikle tahmin- ön kestirim, modelleme ve veri işlem gibi alanlarda yöntemin başarısı ve uygulanabilirliği test edilmiştir.

Bu çalışmada Yapay Sinir Ağlarının iki farklı türü olan Çok katmanlı Algılayıcı ve Radyal Taban Fonksiyonlu Ağlar gravite ve deprem aylık frekans verilerine uygulanmıştır. Çalışma alanı olan Batı Anadolu'nun tektonik ve jeolojik açıdan çok ilgi çeken ve birçok araştırmacının çalıştığı bölgelerden biri olması nedeniyle uygulanan bu yöntemlerin daha önceki sonuçlarla karşılaştırılması söz konusu olabilmektedir.

Bilindiği gibi gravite yönteminin çok çözümlülüğü modelleme çalışmalarını güçleştirmektedir. Bugüne kadar farklı yöntemler gravite modellemesi amacıyla kullanılmış ve çok çözümlülük problemi aşılmaya çalışılmıştır. Bu çalışmada Yapay Sinir Ağları yöntemi kullanılarak gravite modellemesi amaçlanmıştır. Batı Anadolu da özellikle grabenler üzerinde alınan gravite kesitleri Çok Katmanlı Algılayıcı ve Radyal Taban Fonksiyonlu ağlar ile değerlendirilerek bölgenin tortul kalınlığı, kabuk kalınlığı ve birimler arası yoğunluk farkları elde edilmiştir. Batı Anadolu' nun temel grabenlerinden olan Gediz ve Büyük Menderes gravite verileri YSA ile değerlendirilmiştir. Gediz grabeni için ortalama tortul kalınlığı yaklaşık 0,5-2,5 km olarak saptanmıştır. Büyük Menderes için elde edilen tortul kalınlığı ise yaklaşık 0,3-3,2 km olarak bulunmuştur.

Bölge sismolojik açıdan açılma rejiminin sonucu oluşan grabenler ve graben tektoniği nedeniyle aktiftir. Türkiye genelinde birinci deprem kuşağı içinde yer alan bölgede aletsel dönemden günümüze yıkıcı depremler meydana gelmiştir. Bu depremleri önceden tahmin edebilme ve gereken önlemleri alabilme günümüzde oldukça ilgi çeken konulardan biridir. Bölgede meydana gelen depremlerin aylık oluş sayıları düzenlenerek Yapay Sinir Ağları yöntemleriyle deprem aylık frekans ön kestirimi yapılmıştır.

1.1 Yapay zeka ve Yapay Sinir Ağları Tanımı

Yapay zeka, bilgisayarın yada bilgisayar ile kontrol edilen bir makinanın, akıl yürütme, anlam çıkartma, genelleme, algılama, geçmiş deneyimlerden öğrenme gibi genellikle insan zekasına özgü olan görevleri yerine getirme yeteneğidir. Yapay zeka (Artificial İntelligence) teknikleri 4 başlık altında toplanabilir.

- Bulanık Mantık (Fuzzy Logic)
- Uzman Sistemler (Expert Systems)
- Genetik Algoritma (Genetic Algorithm)
- Yapay Sinir Ağları (Artificial Neural Networks)

Yapay zeka tekniklerinden biri olan Yapay Sinir Ağları (YSA) en basit anlamıyla biyolojik sinir sisteminin çalışma prensiplerinden esinlenerek oluşturulmuş matematiksel bir modeldir. Beynin öğrenme yoluyla yeni bilgiler elde etme, hatırlama, problem çözme, tahmin etme gibi yeteneklerinin bilgisayar ortamında oluşturulması YSA'nın temel prensiplerindedir. Herhangi bir olay hakkında girdi ve çıktılar arasındaki ilişkiyi, doğrusal olsun veya olmasın, elde bulunan mevcut örneklerden öğrenerek daha önce hiç görülmemiş olayları, önceki örneklerden çağrışım yaparak ilgili olaya çözümler üretebilme özelliği YSA'nın en temel ve araştırmacıların dikkatini çeken en önemli özelliklerdendir.

Günümüzde YSA farklı alanlarda birçok problemin çözümünde başarıyla uygulanmaktadır. Özellikle insan beyninin çözüm bulduğu öğrenme, ilişkilendirme, sınıflandırma, genelleme, özellik belirleme ve optimizasyon gibi konularda yaygın olarak kullanılmaktadır.

Ayrıca günümüzde bir çok problemin kısa zamanda en iyi şekilde çözülmesi amacıyla kullanılan eniyileme (optimizasyon) tekniklerinden biri olarak gösterilen YSA en iyi çözüm noktasına mümkün olduğunca yaklaşmayı sağlar. Geçmişten günümüze kadar karşılaşılan birçok problemin çözülmesi amacıyla, değişik eniyileme teknikleri geliştirilip uygulanmıştır. Eniyileme teknikleri uygulanış

biçimine göre deterministik ve stokastik olmak üzere iki ana grupta toplanabilir (Haataja, 1999). Yaygın olarak kullanılan deterministik yöntemlerden bazıları Newton, Levenberg-Marquardt, Endik İniş, Gauss-Newton olarak sıralanabilir. Simulated Annealing, Genetik Algoritma, Yapay sinir ağları ise stokastik optimizasyon yöntemlerine örnek olarak gösterilebilir.

1.1.1 Yapay Sinir Ağlarının Tarihçesi

Yapay sinir ağları için ilk adım 19. yüzyılın sonlarında psikolog William James tarafından atılmıştır. James (1890) tarafından yapılan çalışmada beynin hafıza fonksiyonu anlaşılabilir, tahmin edilebilir basit örneklerle açıklanmaktadır. Mühendislik alanında yapay sinir ağlarının temellerini 1940'lı yıllardan sonra Hebb, Mcculloch ve Pitts, gibi bilim adamlarının çalışmaları oluşturmuştur. 1949 yılında Donald Hebb, tarafından geliştirilen 'hebbian öğrenme' öğrenme kuralı günümüzde de birçok öğrenme kuralının temelini oluşturmaktadır (Hebb, 1949; Mcculloch ve Pitts, 1943). YSA çalışmaları tam olarak 1950' li yıllarda başlamıştır. Basit sinir modeline dayalı bir hesaplama modeli, Rosenblatt tarafından 1958 yılında önerilmiş ve perseptron (algılayıcı) diye bilinen tek katmanlı ilk YSA modeli ortaya çıkmıştır. Bu model daha sonraları oluşturulan çok katmanlı algılayıcı modelinin temelidir (Rosenblatt, 1958).

Widrow ve Hoff 1960 yılında bu basit sinir modelini kullanarak öğrenebilen ilk ADALINE (ADaptive LInear NEuron) adı verilen adaptif sistemler üzerinde çalışmış ve delta kuralı diye bilinen, gerçek çıkış ile istenen çıkış arasındaki farka eşit bir hata terimi kullanarak ağırlıkların değiştirildiği öğrenme kuralını ortaya koymuşlardır (Widrow ve Hoff 1960). 1970' li yılların sonunda ortaya çıkarılan MADALINE ise birden fazla Adaline ünitesinden oluşmuş ağdır. 1970' li yıllarda YSA çalışmaları duraklama dönemini yaşamıştır.

1982 ve 1984 yıllarında Hopfield tarafından yayınlanan çalışmalar ile yapay sinir ağlarının genelleştirilebileceği görülmüştür. Hopfield tekrar beslemeli (recurrent)

YSA modeli ortaya atılmış ve bunun pratik optimizasyon problemlerinde kullanılabilirliğini göstermiştir.


Kohonen 1984 de kendi kendine öğrenme nitelik haritalarını (Self-Organizing Maps, SOM) geliştirmiştir. 1988 yılında Grossberg, Adaptif Rezonans Teorisi (Adaptive Resonance Theory, ART) adı altında bir YSA yapısını geliştirmiştir (Grossberg, 1988a). Bu öğretmensiz öğrenme konusunda zamanın geliştirilmiş en karmaşık yapay sinir ağı modeli olmuştur.

Rumelhart 1986 yılında “Parallel Distributed Processing” adlı kitabında, ileri beslemeli (feed-forward) ağlarda yeni bir öğrenme modeli olan hatanın geriye yayılım algoritmasını (backpropagation algorithm) geliştirmiştir. Geri yayılım algoritması ile çalışan ileri beslemeli yapay sinir ağları kullanımı yaygın ve öğrenilmesi kolay olduğundan birçok araştırmacı tarafından tercih edilmektedir. (Haykin,1999)

1.1.2 Biyolojik Sinir Sistemi

Yapay sinir ağları biyolojik sinir sisteminden esinlenerek geliştirilmiştir. Bu nedenle öncelikle biyolojik sinir sistemi üzerinde durulacaktır. Sinir ağı milyarlarca sinir hücresinin bir araya gelmesi ile oluşmaktadır. Beynimizde yaklaşık 10^{11} adet sinir hücresinin olduğu ve bunların 6×10^{13} ten fazla bağlantısının bulunduğu söylenmektedir (Öztemel, 2003; Sağıroğlu, Beşdok, Erler, 2003).

Biyolojik sinir ağları insan beyninin çalışmasında büyük öneme sahiptir. Beş duyu organından gelen sinyaller algılama ve anlama mekanizmalarını çalıştırır. Beyinde şekillenen sinyaller tekrar sinir sistemi ile organlara eylem olarak iletilir. Bir sinir hücresini oluşturan birimler aşağıda gösterilmektedir.



Şekil 1.1 Biyolojik sinir hücresi (Sağıroğlu ve diğer, 2003).

Şekil 1.1 de de görüldüğü gibi temel bir biyolojik sinir hücresi "soma", "akson", "sinaps" ve "dendrite" lerden oluşmaktadır. Sinaps, sinir hücrelerini birbirine bağlayan ve bir sinir hücresinden diğerine elektrik sinyallerin geçmesini sağlayan boşluklardır. Sinaps'lar yoluyla sinyaller dendrit' lere ve dolayısı ile soma'ya iletilir. Soma'da gelen sinyal işlenerek sinir hücresi kendi sinyalini oluşturur. Oluşturulan sinyal akson yardımıyla sinaps'lardan geçerek dendrit'lere gönderilir. Dendrit'ler bu sinyalleri soma'ya taşıyarak bir çıktı oluşmasını sağlarlar. Sinirler elektrik sinyalini hücre duvarındaki voltajı değiştirerek üretirler. Bu durum hücre içinde ve dışında dağılmış bulunan iyonlar aracılığı ile olur. Bu iyonlar sodyum, potasyum, kalsiyum ve klor gibi iyonlardır. Potasyum yoğunluğu sinirin içinde sodyum yoğunluğu ise sinirin dışındadır. Bir hücre diğer bir hücreye elektrik enerjisini bu iyonlar vasıtasıyla iletir. Bazı iyonlar magnetik kutuplaşmaya neden olurken bazıları kutuplaşmadan kurtulup hücre zarını açarak iyonların soma'ya geçmesini sağlar. Sinyallerin bir hücreden diğerine akmasını sağlayanda bu kutuplaşmanın azalmasıdır.

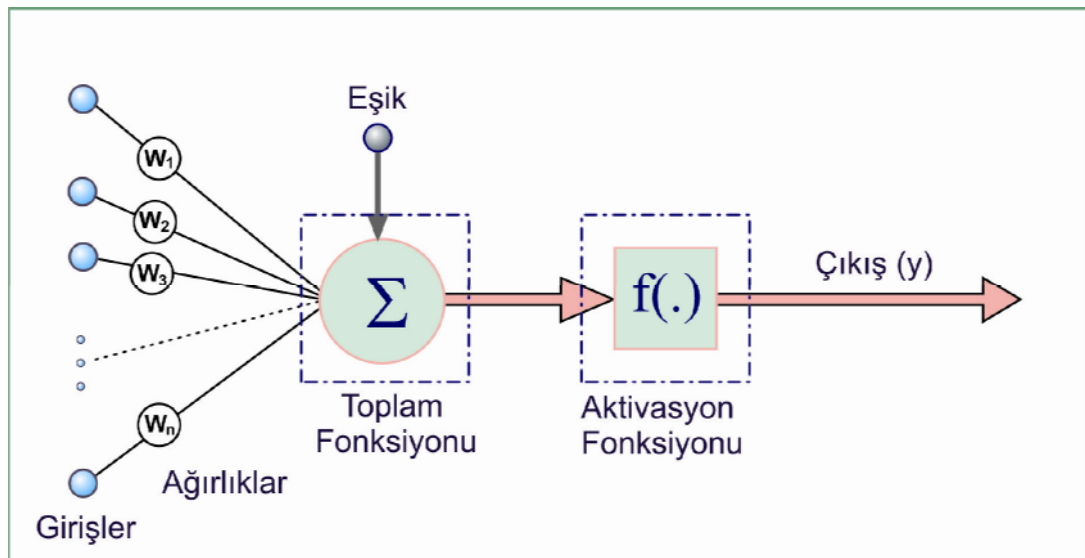
Sinyaller hücrenin etkinliğini (dürtüsünü) belirler. Bir hücrenin etkinliği, hücreye gelen sinaps sayısı, sinaps'lardaki iyonların konsantrasyonu, sinaps'ın sahip olduğu güç olmak üzere üç faktöre bağlıdır. Dendrit tarafından alınan sinyaller hücrede birleştirilerek bir çıkış darbesi üretilip üretilmeyeceğine karar verilir. Dendrit'lerce

alınan bir giriş, harekete geçirici (tetikleyici, pozitif) ya da yasaklayıcı (negatif) olabilir. Dendrit'lere geçirilen iletiler soma'da birleştirilerek elektriksel bir çıktı oluştururlar. Soma'ya gelen girdilerin toplamı akson üzerinde çıktı oluşturacak değere ulaştığında (eşik seviyesi) akson bir çıkış sinyali üretir. Akson'un çıkış sinyali üretmesi akson ateşlendi (fired) şeklinde ifade edilir.

Biyolojik beynin en önemli özelliklerinden biri de öğrenme olayıdır. Öğrenilen her yeni bilgi, beyin fonksiyonlarını da etkileyerek davranışlarda kendini gösterir. YSA'nın geliştirilmesinde insan beyninin bu özelliği dikkate alınmaktadır (Haykin, 1999).

1.2 Yapay Sinir Ağı ve Temel Elemanları

YSA'nın en temel elemanı algılayıcıdır (perceptron). İlk olarak 1958 yılında Frank Rosenblatt tarafından geliştirilmiştir. Şekil 1.2 de görüldüğü gibi algılayıcı altı ana bölümden oluşmaktadır. Bunlar, girişler (x_i), ağırlıklar (w_i), eşik (b_i), toplam fonksiyonu (Σ), aktivasyon fonksiyonu (f) ve çıkış değeri y ' dir. Bu altı temel eleman aşağıda detaylı olarak açıklanmaktadır.



Şekil 1.2 Yapay sinir hücresi.

- **Girişler:** Yapay sinir hücresine dışarıdan veya diğer sinir hücrelerinden gelen bilgilerdir.
- **Ağırlıklar:** Ağırlıklar yapay sinir hücresine gelen bilgiyi diğer sinir hücrelerine değiştirerek aktarmaya yarayan bağlantılardır. Girdi değerleri ağırlıklarla çarpılarak diğer sinir hücresine iletilir. Ağırlıklar negatif ya da pozitif değerler olabilir. Ağırlıklar nöron yapısında synapselere karşılık gelmektedir.
- **Eşik:** Sinir hücresinin ya da ağın çıktısının sıfır olmasını engellemek için eşik değeri kullanılır.
- **Toplam Fonksiyonu:** Hücreye gelen net girdinin hesaplanmasını sağlayan fonksiyondur. En yaygın kullanım şekli her girdi değerinin kendi ağırlığıyla çarpılarak toplanmasıdır. Ancak farklı fonksiyonlar da bu amaç için kullanılabilir.
- **Aktivasyon Fonksiyonu:** Hücreye gelen net girdiye karşılık hücrenin üreteceği çıktıyı hesaplar. Farklı fonksiyonlar aktivasyon fonksiyonu olarak kullanılabilir. Çok katmanlı algılayıcı gibi ağlarda bu fonksiyonun hatanın geri yayılım aşamasında türevi alındığı için türevi alınabilir bir fonksiyon olması gerekmektedir. Çıktıyı hesaplamak için kullanılan aktivasyon fonksiyonlarından bazıları adım (step), eşik (threshold), sigmoid ve hiperbolik tanjant fonksiyondur. Sigmoid fonksiyonu;

$$f(v) = \frac{1}{1 + e^{-v}} \quad (1)$$

bağıntısı ile tanımlanır. Adım fonksiyonunda gelen net girdinin belirlenen bir eşik değerinin altında yada üstünde olması durumuna göre çıktının değeri 1 yada 0 olur. Adım fonksiyonu,

$$f(v) = \begin{cases} 1, & \text{eğer } v > \text{eşik değeri} \\ 0, & \text{eğer } v \leq \text{eşik değeri} \end{cases} \quad (2)$$

olarak tanımlanır.

Eşik (threshold) fonksiyonu girdinin 0 yada 1 den büyük olmasına göre değer alır. 0 ile 1 arasında değişen değerler de alabilir. Bunların dışında kalan değerleri almaz. Eşik fonksiyonu,

$$f(v) = \begin{cases} 0, & \text{eğer } v \leq 0 \\ v, & \text{eğer } 0 < v < 1 \\ 1, & \text{eğer } v \geq 1 \end{cases} \quad (3)$$

bağıntısıyla verilmektedir. Hiperbolik tanjant fonksiyonu ise girdilerin tanjant fonksiyonundan geçirilmesiyle hesaplanmaktadır. Hiperbolik tanjant,

$$f(v) = \frac{e^v + e^{-v}}{e^v - e^{-v}} \quad (4)$$

bağıntısıyla tanımlanır.

Şekil 1.3 te YSA' da en yaygın olarak kullanılan transfer fonksiyonları görülmektedir. Bunların dışında Gaussian ve Sinüs fonksiyonu da bilinen aktivasyon fonksiyonlarıdır.

- **Çıktı:** Girdi ve ağırlıkların çarpımının toplamıdır. Elde edilen toplam aktivasyon fonksiyonu ile ağırlık ürettiği çıktıya dönüşür. Yapay sinir hücresinin y çıktısı;

$$y = f(v) = f\left(\sum_{i=1}^M w_i x_i + b\right) = w x^T + b \quad (5)$$

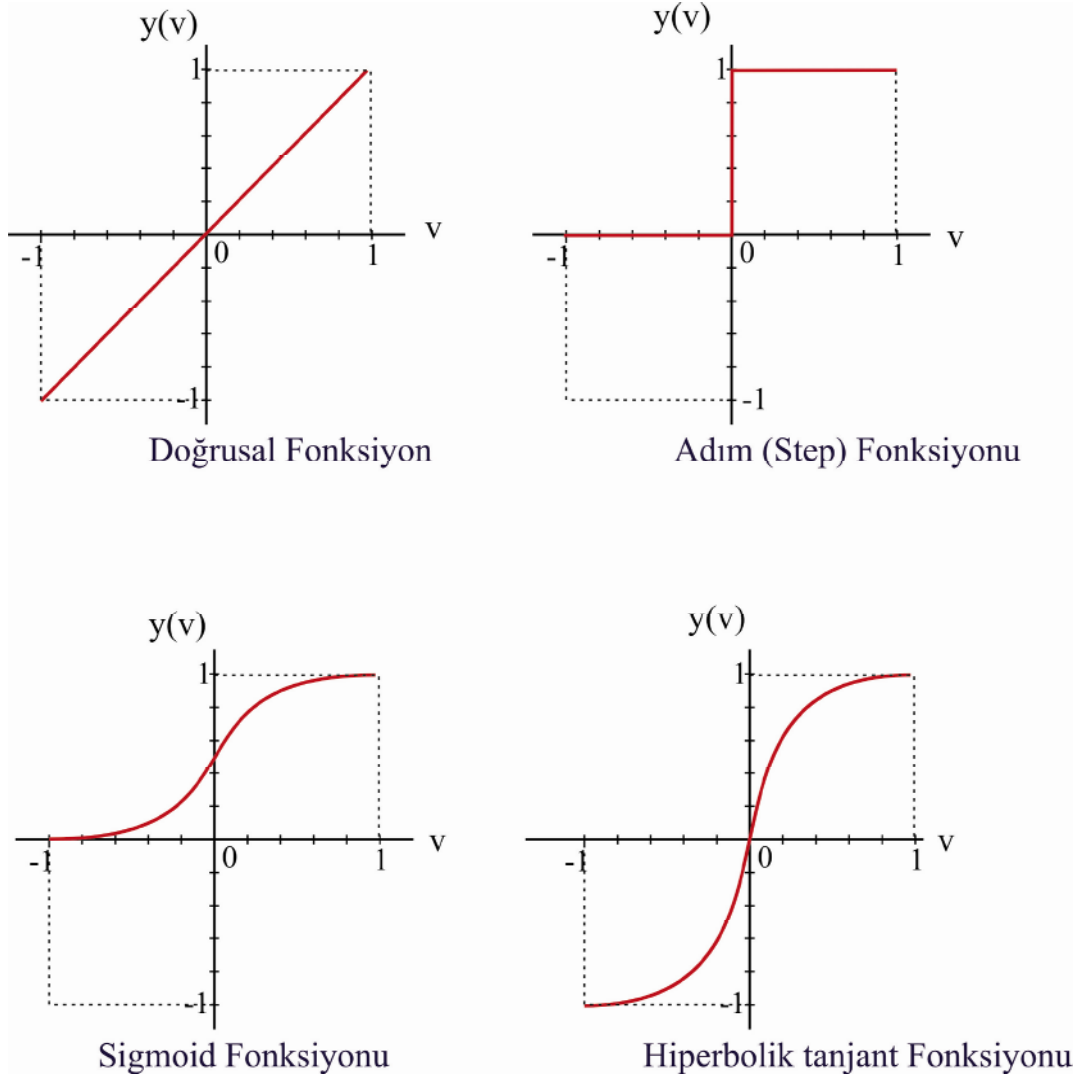
bağıntısıyla verilir. Bağlıntıdaki w ağırlık değeri, x girdi değeri b ise nöronun eşik değerini göstermektedir. Girdi vektörü;

$$x = \begin{bmatrix} x_1 & x_2 & \dots & x_M \end{bmatrix}^T \quad (6)$$

olarak tanımlanır. Ağa girilen $1 \times M$ boyutundaki vektördür. Ağırlık değerleri ise;

$$w = [w_1 \ w_1 \ \dots \ w_M] \quad (7)$$


olarak tanımlanır. Eşik değeri olan b ise katmandaki her nörona bağlanan değerdir ve katmandaki nöron sayısı kadar eşik değeri mevcuttur.



Şekil 1.3 En yaygın kullanılan transfer fonksiyonları.

Biyolojik sinir sistemindeki birimler ile yapay sinir ağlarındaki birimlerin görevleri ve terminolojideki isimleri Şekil 1.4 de özetlenmektedir. Biyolojik sinir sistemindeki sinir hücresi YSA'da da sinir, nöron yada işlem elemanı olarak isimlendirilir. Dendritler toplam fonksiyonunun, hücre gövdesi aktivasyon

fonksiyonunun, aksonlar YSA çıktısının, sinapslar ise ağırlıkların görevlerini yerine getirmektedir.



Şekil 1.4 Biyolojik ve yapay sinir hücrelerinin birlikte gösterimi.

1.3 Yapay Sinir Ağlarının Sınıflandırılması


Yapay sinir ağları, yapılarına ve öğrenme algoritmalarına göre çeşitli sınıflara ayrılmaktadır. Yapılarına göre ileri beslemeli ve geri beslemeli ağlar olmak üzere iki, öğrenme algoritmalarına göre ise öğretmenli öğrenme, öğretmensiz öğrenme ve takviyeli öğrenme olmak üzere üç grupta sınıflanmaktadır.

1.3.1 Yapılarına Göre Ağlar

Yapılarına göre ağlar ileri beslemeli ve geri beslemeli olmak üzere iki gruba ayrılır. Bu ağlar hakkında detaylı bilgi aşağıda verilmektedir.

1.3.1.1 İleri Beslemeli Ağlar


İleri beslemeli bir ağda nöronlar genellikle katmanlara ayrılmışlardır. Girdiler, giriş katmanından çıkış katmanına doğru tek yönlü bağlantılarla iletilir. Nöronlar bir katmandan diğer bir katmana bağlantı kurarlar, aynı katman içerisinde birbirleri ile bağlantıları bulunmaz. Şekil 1.5 de ileri beslemeli ağ için blok diyagram gösterilmiştir. İleri beslemeli ağlara örnek olarak çok katmanlı algılayıcı (Multi Layer Perceptron-MLP) ve LVQ (Learning Vector Quantization) ağları verilebilir.



Şekil 1.5 İleri beslemeli ağ diyagramı.

1.3.1.2 Geri Beslemeli Ağlar

Geri beslemeli sinir ağı, çıkış ve ara katmanlardaki çıkışların, giriş birimlerine veya önceki ara katmanlara geri beslendiği bir ağ yapısıdır. Böylece, girişler hem ileri yönde hem de geri yönde aktarılmış olur. Şekil 1.6 da geri beslemeli bir ağ görülmektedir. Bu çeşit sinir ağlarının dinamik hafızaları vardır ve bir andaki çıkış hem o andaki hem de önceki girişleri yansıtır. Bu özelliğinden dolayı, özellikle ön kestirim uygulamaları için uygundur. Bu ağlar çeşitli tipteki zaman serilerinin tahmininde oldukça başarı sağlamışlardır. Bu ağlara örnek olarak Hopfield, SOM, Elman ve Jordan ağları verilebilir.



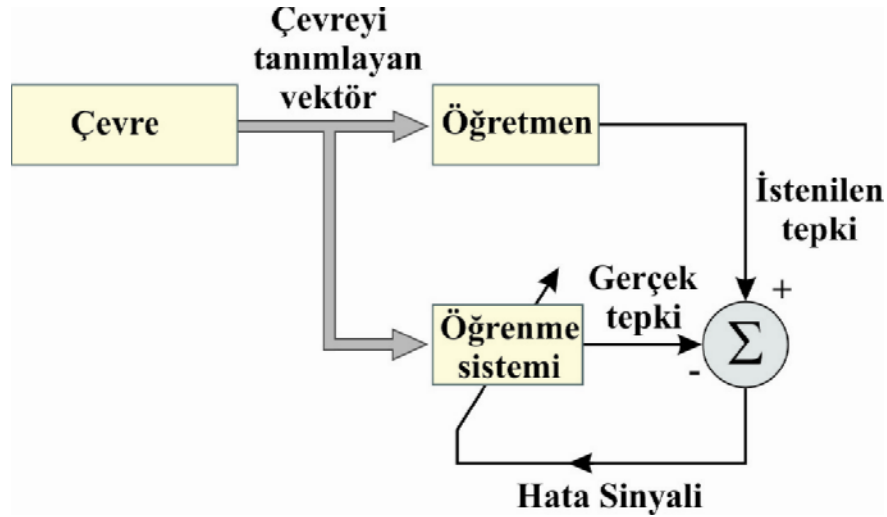
Şekil 1.6 Geri beslemeli ağ diyagramı.

1.3.2 Öğrenme Algoritmalarına Göre Ağlar

Öğrenmenin bir çok tanımı olmasına rağmen Simon (1983) öğrenmeyi zaman içinde yeni bilgilerin keşfedilmesi yoluyla davranışların iyileştirilmesi süreci olarak tanımlamaktadır (Simon, 1983). Yapay sinir ağlarında ise öğrenme yoluyla ağdaki ağırlıkların değiştirilmesi sağlanmaktadır. Bunun için genel olarak üç öğrenme metodundan ve bunların uygulandığı değişik öğrenme kurallarından söz edilebilir.

1.3.2.1 Öğretmenli Öğrenme (Supervised Learning)


Bu tip öğrenmede, YSA'ya giriş değerleri ve bunlara karşılık gelen çıkış değerleri verilir. İstenilen ve gerçek çıktı arasındaki farka (hataya) göre nöronlar arası bağlantıların ağırlığı en uygun çıkışı elde etmek için düzenlenir. Sisteme verilen girdi ve bunlara karşılık gelen çıktılardan oluşan eğitim seti yardımıyla ağ eğitilerek ağırlıklar değiştirilir. Giriş ve çıkış değerlerinden oluşan eğitim seti öğretmen yada danışman görevini görmektedir. Şekil 1.7 de danışmanlı öğrenme yapısı gösterilmiştir. Widrow-Hoff tarafından geliştirilen delta kuralı, Rumelhart ve McClelland (1986) tarafından geliştirilen genelleştirilmiş delta kuralı veya geri besleme (back propagation) algoritması danışmanlı öğrenme algoritmalarına örnek olarak verilebilir.



Şekil 1.7 Öğretmenli öğrenme (Haykin, 1999).

1.3.2.2 Öğretmensiz Öğrenme (Unsupervised Learning)

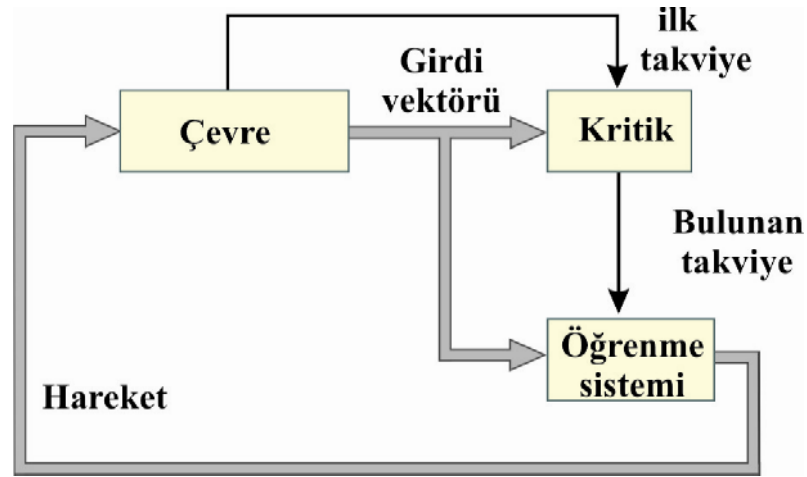
Girişe verilen örnekten elde edilen çıkış bilgisine göre ağ sınıflandırma kurallarını kendi kendine geliştirmektedir. Bu öğrenme algoritmalarında, istenilen çıkış değerinin bilinmesine gerek yoktur. Öğrenme süresince sadece giriş bilgileri verilir. Sisteme girişlere karşılık gelen çıkış değerleri girilmez. Bir eğitim seti mevcut değildir. Ağ daha sonra bağlantı ağırlıklarını aynı özellikleri gösteren desenler oluşturmak üzere ayarlar. Şekil 1.8 de danışmansız öğrenme yapısı gösterilmiştir. Grossberg (1986) tarafından geliştirilen ART (Adaptive Resonance Theory) veya Kohonen (1984) tarafından geliştirilen SOM (Self Organizing Map) öğrenme kuralı danışmansız öğrenmeye örnek olarak verilebilir.



Şekil 1.8 Öğretmensiz öğrenme (Haykin, 1999).

1.3.2.3 Takviyeli öğrenme (Reinforcement learning)

Bu öğrenme kuralı danışmanlı öğrenmeye yakın bir metod olmasına rağmen istenilen ağ çıkışının bilinmesine gerek duyulmaz. Hedef çıktıyı vermek için bir eğitim seti yani öğretmen yerine, YSA' ya bir çıkış verilmemekte fakat elde edilen çıkışın verilen girişe karşılık doğruluk derecesini değerlendiren bir kriter kullanılmaktadır. Şekil 1.9 da takviyeli öğrenme yapısı gösterilmiştir. Optimizasyon problemlerini çözmek için Hinton ve Sejnowski'nin (1986) geliştirdiği Boltzmann kuralı takviyeli öğrenmeye örnek olarak verilebilirler.



Şekil 1.9 Takviyeli öğrenme (Haykin, 1999).

1.3.3 Öğrenme Kuralları

YSA'ların en önemli özelliklerinden biri çevresinden yararlanarak öğrenme yeteneğidir. Öğrenme için geliştirilmiş bir çok kural vardır. En bilinen öğrenme kuralları arasında Hebb, Oja, Delta, Hopfield, Kohonen, Widrow Hoff öğrenme kuralı gibi birçok öğrenme kuralı bulunmaktadır. Bu bölümde en temel öğrenme kurallarına değinilecektir.

1.3.3.1 Hebb Kuralı

İlk ve en çok bilinen öğrenme kuralıdır. 1949 yılında Donald Hebb tarafından geliştirilmiştir. Hebb'in öğrenme kuralına göre, aralarında doğrudan bağlantı olan bir nöron diğer nöron ile eş zamanlı aktive oluyorsa, bu hücrelerin arasındaki bağlantının ağırlığı bir miktar artırılır.

Hebb kuralı, x_j giriş ve y_k çıkış sinyaline sahip bir k nöronu için n . adımda matematiksel olarak aşağıdaki gibi tanımlanabilir.

$$\Delta w_{kj}(n) = \mu y_k(n)x_j(n) \quad (8)$$

Bağıntıdaki μ öğrenme hızını belirleyen bir sabit, w_{kj} k nöronunun sinaptik ağırlığı, x_j ve y_k nöronun girdi ve çıktı sinyallerini göstermektedir. (Haykin, 1999)

1.3.3.2 Delta Bar Delta Kuralı

Yaygın olarak kullanılan öğrenme kuralıdır. Bu kural ağdan istenilen çıktı ile ağı hesapladığı çıktı arasındaki farkın yani hatanın en aza indirilmesini sağlamaya yöneliktir. Bu öğrenme kuralına göre ağırlıklar ağın ortalama karesel hatasını en küçük yapacak şekilde değiştirilir. Bu kurala aynı zamanda Widrow-Hoff kuralı ve En Küçük Ortalamaların Karesi kuralı da denmektedir.

1.3.4 Yapay Sinir Ağlarının Avantaj ve Dezavantajları

1.3.4.1 Avantajları

- Matematiksel olarak modellenmesi mümkün olmayan karmaşık problemleri çözebilirler.
- Doğrusal olmayan ilişkileri de kolaylıkla modelleyebilmektedirler.
- YSA'larının çalışması geleneksel sistemlerden hızlıdır. (Özellikle paralel işleme özelliği olan sistemlerde)


- Değişikliklere karşı yeniden eğitilebilirler. Ortama uyum yetenekleri vardır.
- Paralel çalışabilmeleri gerçek zamanlı kullanımlarını kolaylaştırmaktadır.

1.3.4.2 Dezavantajları

- YSA model seçiminde, ağ topolojisinin belirlenmesinde ve ağ oluşturulmasında kesin kurallar yoktur. Kullanıcı kendi deneyimine göre ağ yapısını belirler.
- Örneklerin tasarımında da bir kurallar seti yoktur. Farklı tasarımlarda farklı performans verebilir.
- Ağ davranışı açıklanamaz.
- Eğitim süreci seçilen ağa ve arzulanan hedef kriterlere bağlı olarak uzun sürebilmektedir.
- Eğitim seti için fazla veriye ihtiyaç duyulmaktadır.

1.4 Yapay Sinir Ağlarının Jeofizikteki Uygulamaları

Son yıllarda jeofizikte yapay sinir ağlarına olan ilgi artmaktadır. Farklı problemlerin çözümünde kolaylıkla uygulanabilir olması araştırmacıların ilgisini çekmektedir. Şekil 1.10 da 1999-2009 yılları arasında yerbilimlerinde YSA uygulamalarının yer aldığı SCI-EXP dergilerdeki yayın sayıları görülmektedir. Yayınlar Web of science' den araştırılarak derlenmiştir.



Şekil 1.10 Yer bilimlerinde yapay sinir ağları uygulamalarının SCI-EXP dergilerde yayınlanmış makale sayıları (Web of science' dan derlenmiştir).

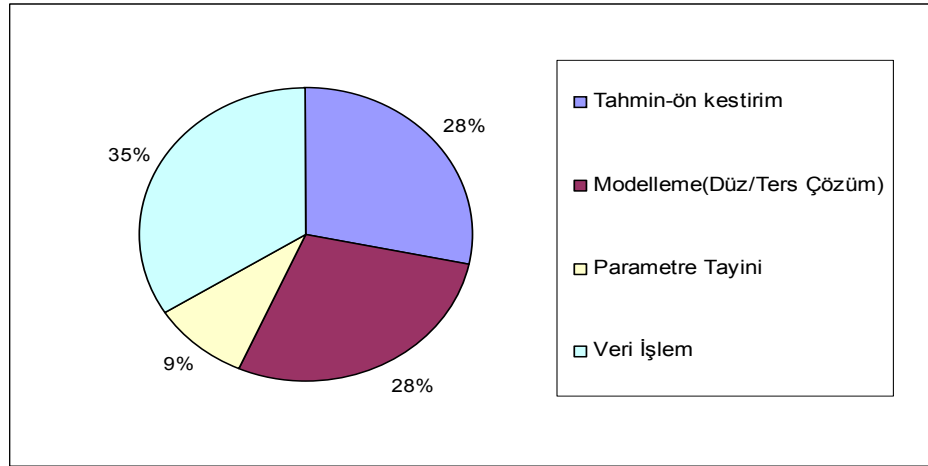
Jeofizikte kullanılan yöntemler yapay ve doğal kaynaklı olmak üzere iki gruba ayrılır. Yapay kaynaklı yöntemlerde dışarıdan etki etme imkanı varken doğal kaynaklı yöntemlerde herhangi bir etki söz konusu değildir. Doğal kaynaklı yöntemlerde aynı anomaliyi verebilecek başka yer altı modelleri de olabileceğinden bu sorun çok çözümlülüğü beraberinde getirmektedir.

Son yıllarda YSA çeşitli jeofizik yöntemlerde uygulanmaktadır. Çeşitli yayınların derlenmesiyle oluşturulan Tablo 1.1 de bugüne kadar jeofizikte yapay sinir ağlarının hangi alanlarda ve hangi amaçlarla kullanıldığı özetlenmeye çalışılmıştır.

Tablo 1.1 incelendiğinde Yapay Sinir ağlarının jeofizikte ön kestirim, modelleme ve veri işlem amacıyla yaygın olarak uygulandığı görülmektedir. Çok katmanlı algılayıcı türü ağlar birçok problemin çözümünde olduğu gibi jeofiziksel uygulamalarda da yaygın kullanım alanına sahip olmuştur. Tablo 1.1 deki çalışmaların uygulama oranlarını elde etmek amacıyla pay diagramlar oluşturulmuştur.


Tablo 1.1 Yapay sinir ağlarının jeofizik çalışmalardaki dağılımı.

Tahmin /Ön kestirim	Modelleme/Ters Çözüm	Parametre Tayini	Veri İşlem
Katalog verilerinden yararlanarak deprem oluş zamanı ve deprem aylık frekans değeri (ÇKA) (Bodri,2001), (Sri Lakshmi ve Tiwari,2009)	Elektrik ve sismik verilerin 1D ters çözümü (ÇKA) (Macias ve diğer., 2000)	NMO' dan sismik hız tayini (ÇKA) (Macias ve diğer., 1998)	Sismik dekonvolüsyon, sismik wavelet (HP) (Wang ve Mendel, 1992)
EM verilerden yer altı yapılarının yerlerinin saptanması (ÇKA), (SOM) (Poulton ve diğer., 1992)	DC rezistivite verilerinin ters çözümü (ÇKA) (El-Qady ve Ushijima, 2001)	Sismolojide ilk varışların tayini (Dai ve MacBeth, 1996)	MT transfer fonksiyonunun hesaplanması (ÇKA) (Manoj ve Nagarajan, 2003)
Farklı volkanik bölgelerde sismisite ve yer değiştirmenin tahmini (ÇKA) (Luongo ve diğer., 2004)	MT verilerinin ters çözümü (ÇKA), (HP), (Macias ve diğer., 2000) (Zhang ve Paulson, 1997)	Peak ground acceleration (ÇKA) (Kerh ve Chu, 2002)	Gravite-manyetik verilerden yararlanarak jeolojik yapı sınırı (CNN) (Aydoğan ve diğer., 2003) (Ucan ve diğer., 2002)
Sismik artçı şokların yerinin ve zamanının tahmini (ÇKA) (SOM) (Lin ve Mohamed, 1999) (Allameh Zadeh,2004)	Sismik dalga biçimi ters çözümü (ÇKA) (He ve Zhou, 2003)		Arkeolojik verilerin değerlendirilmesi (CNN) (Albora ve Uçan, 2005)
Jeofizik kuyu loglarından termal kondaktivitenin tahmini (ÇKA) (Goutorbe ve diğer., 2006)	AEM verilerinin 1 boyutlu ters çözümü (Ahl, 2003)		Deniz sismik verilerinde tekrarlı yansımaların belirlenmesi (ÇKA) (Essenreiter ve diğer., 2003) Tekrarlı yansımaların belirlenmesi ve sınıflandırılması (SOM) (Essenreiter ve diğer., 2001)
Wireline logtan porozite ve permeabilitenin tahmini (ÇKA) (Hele ve diğer., 2001)	Gravite anomalisinin düz çözümü (ÇKA) (Osman ve diğer., 2007)		Sismik yansıma çalışmalarında veri kalitesini arttırmak için gürültülerin giderilmesi (ÇKA),(RTFA) (Van der Baan ve Jutten, 2000)
Kuyu logu verilerinden kırılma frekansının tahmini (ÇKA) (FitzGerald ve diğer., 1999)	Sismik ters çözüm (RTFA) (Baddari ve diğer., 2009)		Manyetik rejyonel/ rezidüel ayrımı , Bouguer anomali haritasının ayrımı (CNN) (Albora ve diğer., 2001)



Şekil 1.11 Yapay Sinir Ağlarının Jeofizikte kullanım alanları ve oranları.

Tablo 1.1 den yararlanarak elde edilen Şekil 1.11 deki diyagram incelendiğinde yapay sinir ağlarının veri işlem, modelleme ve ön kestirim amacıyla jeofizikte kullanıldığı görülmektedir. Süzgeç, sınıflama gibi veri işlem aşamalarında alternatif bir yöntem olarak kullanılmaktadır.



Şekil 1.12: Jeofizikte yaygın olarak kullanılan Yapay Sinir Ağı türleri ve kullanım oranları.

Tablo 1.1 den yararlanarak oluşturulan Şekil 1.12 deki diyagramda en çok kullanılan ağ türünün çok katmanlı algılayıcı olduğu görülmektedir. Gerek kolay matematiksel yaklaşımı ve gerekse bir çok alanda kolay uygulanabilirliği bu ağ türünün jeofizikte de tercih edilmesine neden olmuştur.

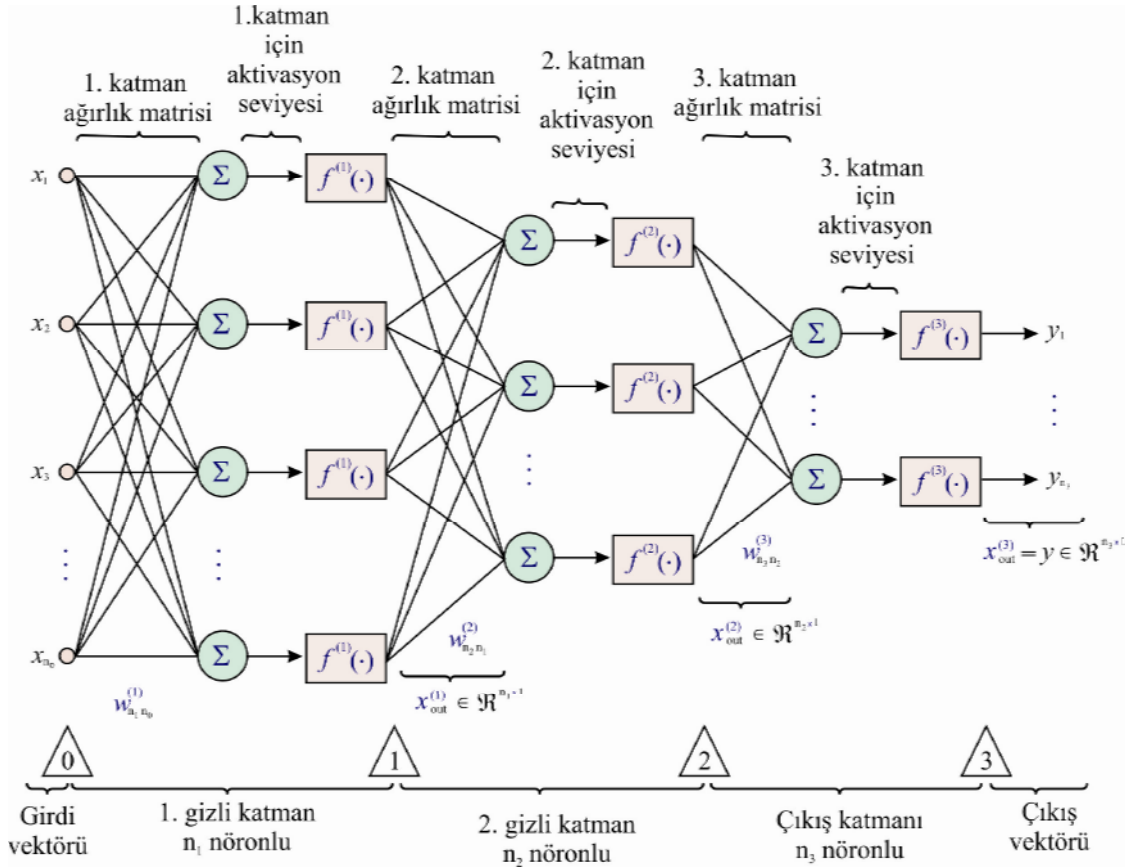
BÖLÜM İKİ

KULLANILAN YÖNTEMLER

2.1 Çok Katmanlı Algılayıcı (Multilayer Perceptron)

Yapay sinir ağlarında uygulama kolaylığı ve bir çok problemin çözümü açısından uygunluğu nedeniyle Çok Katmanlı Algılayıcı (ÇKA) yaygın olarak kullanılan bir modeldir. Bir girdi katmanı, bir ya da birden fazla gizli (ara) katman ve bir çıkış katmanından oluşmaktadır. Katmanlardaki nöronlar verilen girdiyi işleyerek ve diğer nöronlara ileterek istenilen çıktıya ulaşmayı sağlar. Verilen girdi vektörünün her elemanı ilgili ağırlık ile çarpılıp birbirine eklenerek net girdi hesaplanır. Nöronda hesaplanan net girdiyi çıktıya dönüştürmek için aktivasyon fonksiyonu kullanılır. ÇKA' da türevinin kolay alınabilmesi hatanın geri yayılma sürecinde işlem kolaylığı sağladığı için aktivasyon fonksiyonu olarak genellikle sigmoid kullanılır. ÇKA'da nöronlar iki katman arasında bağlantıyı sağlar. Ancak aynı katmandaki nöronlar arasında bağlantı yoktur. Bu yapısı nedeniyle veri akışı girdi katmanından çıktı katmanına doğru ilerler. Ağırlıklar ağına çıktısı ile istenilen çıktının arasındaki farkın azaltılmasını sağlayacak yönde hesaplanır.

ÇKA öğretmenli öğrenme sınıfında olan bir modeldir. Öğrenmenin amacı, verilen bir problemdeki bilinen girdi-çıkış çiftinin ağı eğitmek için kullanılması ve daha sonra eğitilen bu ağ ile bir girişe karşılık doğru sonuç üretmesinin sağlanmasıdır. YSA' ların hiç öğrenmedikleri girişlere karşılık gelen çıkışları doğru şekilde verebilmelerine YSA' ların genelleme (generalization) özelliği denir. En yaygın ve en çok kullanılan öğrenme algoritması geri yayılım algoritmasıdır. Anlaşılması kolay ve matematiksel olarak kolayca ispatlanabilir olmasından dolayı en çok tercih edilen öğrenme algoritmasıdır. Bu algoritma, hataları çıkıştan girişe geriye doğru azaltmaya çalışmasından dolayı geri yayılım (back propagation) ismini almıştır .



Şekil 2.1 Çok katmanlı algılayıcı (Ham ve Kostanic, 2000).

Eğitim tamamlandıktan sonra ileri beslemeli yapı için çıktı değeri ;

$$y = f^{(3)} \left[W^{(3)} f^{(2)} \left[W^{(2)} f^{(1)} \left[W^{(1)} \mathbf{x} \right] \right] \right] \quad (9)$$

bağıntısıyla verilir.

2.1.1 Geri Yayılım Algoritması (Backpropagation Algorithm)

Geril yayılma algoritması (genelleştirilmiş delta kuralı) ilk olarak 1970'li yıllarda geliştirilmiştir. Bu algoritmanın geliştirilmesinde birbirlerinden bağımsız olarak birkaç araştırmacının katkıları olmuştur. Asıl katkı ise Rumelhart, Hinton ve Williams (1986) tarafından yapılmıştır. Geriye yayılım algoritması, yapay sinir ağlarında en çok kullanılan eğitim algoritmasıdır. Bu algoritmanın öğrenmesi

sırasında ağ, her giriş verisini, çıkış nöronlarında sonuç üretmek üzere gizli katmanlardaki nöronlardan geçirir. Daha sonra çıkış katmanındaki hataları bulabilmek için, beklenen sonuç ile elde edilen sonuç karşılaştırılır. Bir sonraki aşamada çıkış hatalarının türevi çıkış katmanından geriye doğru gizli katmanlara geçirilir. Hata değerleri bulunduktan sonra, nöronlar kendi hatalarını azaltmak için ağırlıklarını ayarlar. Ağırlık değiştirme denklemleri, ağdaki performans fonksiyonunu en küçük yapacak şekilde düzenlenir. Geri yayılım algoritmasında kullanıcı, gizli katman sayısı, gizli katmandaki nöron sayısı, aktivasyon fonksiyonu (sigmoid, tanjant hiperbolik, doğrusal, v.b) ağırlıkların ağa tanıtılması, öğrenme katsayısı ve momentum, eşik, hata hesaplanması, ağırlıkların düzenlenmesi gibi parametreleri kontrol edebilmektedir (Poulton, 2001).

Geril yayılım algoritması en genel haliyle açıklanırsa çıktı katmanındaki j . nöronun n . örnek için hata sinyali aşağıdaki gibi tanımlanmaktadır.

$$e_j(n) = d_j(n) - y_j(n) \quad (10)$$

Burada $d_j(n)$ ve $y_j(n)$ n . örnek için sırasıyla çıkış katmanındaki arzulanan ve gerçek hata değerlerini belirtir.

ÇKA yapay sinir ağları için kullanılan standart geril yayılım algoritması anlık hatayı tanımlayan enerji fonksiyonunun azaltılmasında kullanılan en dik iniş (steepest descent) gradient tabanlı bir algoritmadır.

En aza indirgenmesi arzulanan hata fonksiyonu 3 katmanlı bir ağ için;

$$E_q = \frac{1}{2} \sum_{h=1}^{n_3} (d_{qh} - y_h)^2 \quad (11)$$

şeklinde yazılır. Burada d_{qh} q . giriş verisi için h . nörondaki arzulanan ağ çıkışını temsil eder. $y_h^{(3)}$ ise çıkış katmanındaki h . nöron için gerçek (hesaplanan) çıkış değerini verir.

En dik iniş yaklaşımı kullanılarak ağırlık herhangi bir katmanı için ağırlık değişimi,

$$\Delta w_{ji}^{(s)} = -\mu^{(s)} \frac{\partial E_q}{\partial w_{ji}^{(s)}} \quad (12)$$

bağıntısıyla verilir. Burada s ilgili ara katman ve $\mu^{(s)} > 0$ karşılık gelen öğrenme katsayısıdır.

(12) bağıntısı her bir ilgili katman için zincir kuralına göre tekrar

$$\Delta w_{ji}^{(s)} = -\mu \frac{\partial E_q}{\partial v_j^{(s)}} \frac{\partial v_j^{(s)}}{\partial w_{ji}} \quad (13)$$

bağıntısıyla yazılır. Burada $v_j^{(s)}$ s . katmandaki aktivasyon fonksiyonunun girişini verir. Eğer (13) denklemindeki kısmi türevler tek tek hesaplanırsa elde edilen ağırlık değişimleri genel olarak,

$$w_{ji}^{(s)}(k+1) = w_{ji}^{(s)}(k) + \mu^{(s)} \delta_j^{(s)} y_i^{(s-1)} \quad (14)$$

bağıntısı ile yazılır. Burada $\delta_j^{(s)}$ ilgili katmandaki yerel hata olarak verilir ve çıkış katmanı için bu hata

$$\delta_j^{(s)} = (d_{qh} - y_j^{(s)}) g(v_j^{(s)}) \quad (15)$$

ile ifade edilir. Burada $g(\cdot)$ doğrusal olmayan aktivasyon fonksiyonunun türevini ifade eder. Yerel hata ara katmanlar için,

$$\delta_j^{(s)} = \left(\sum_{h=1}^{ns+1} \delta_h^{(s+1)} w_{hj}^{(s+1)} \right) g(v_j^{(s)}) \quad (16)$$

denklemleriyle belirlenir (Ham ve Kostanic, 2000).

(14) denkleminde verilen ifadeye momentum katsayısı eklenerek ağırlık değişimi

$$\Delta w_{ji}^{(s)}(k+1) = \mu^{(s)} \delta_j^{(s)}(k) y_i^{(s)}(k) + \alpha \Delta w_{ji}^{(s)}(k-1) \quad (17)$$

denkleminle ifade edilir. Bağlıdaki α genellikle pozitif değerler alan momentum katsayısıdır (Haykin, 1999). Geri yayılım algoritmasında Levenberg- Marquardt ve momentum terimli gradyan azalması yaygın olarak kullanılan öğrenme algoritmalarıdır.

Levenberg – Marquardt algoritması, Newton ve Gradyen Azalması algoritmalarının en iyi özelliklerinden oluşur. Ağırlıkların yenilenebilmesi için yapılması gereken ilk adım Hessian matrisini elde etmektir. Hessian matrisi, performans fonksiyonunun ağırlıklara göre ikinci dereceden türevlerinin alınmasıyla oluşturulur.

$$H = \begin{bmatrix} \frac{\partial^2 E(w)}{\partial w_1^2} & \frac{\partial^2 E(w)}{\partial w_1 \partial w_2} & \dots & \frac{\partial^2 E(w)}{\partial w_1 \partial w_N} \\ \frac{\partial^2 E(w)}{\partial w_2 \partial w_1} & \frac{\partial^2 E(w)}{\partial w_2^2} & \dots & \frac{\partial^2 E(w)}{\partial w_2 \partial w_N} \\ \dots & \dots & \dots & \dots \\ \frac{\partial^2 E(w)}{\partial w_N \partial w_1} & \frac{\partial^2 E(w)}{\partial w_N \partial w_2} & \dots & \frac{\partial^2 E(w)}{\partial w_N^2} \end{bmatrix} \quad (18)$$

Burada H Hessian matrisi, E performans fonksiyonu ve w ise ağırlık sinaptik ağırlıklarıdır. Ağırlıkların yenilenebilmesi için Hessian matrisinin tersinin bulunması gereklidir. Ancak çok karmaşık bir yapay sinir ağı için Hessian matrisinin hesaplanması güçtür. Bu nedenle Levenberg-Marquardt algoritması Quasi-Newton algoritmalarında olduğu gibi bu matrisin yaklaşık değerini kullanmaktadır. Levenberg-Marquardt için Hessian matrisinin yaklaşık değeri;

$$H(k) \approx J^T(k)J(k) + \mu(k)I \quad (19)$$

olarak tanımlanır. Bağlıdaki μ Marquardt parametresi, I birim matris, k adım sayısı, J ise Jakobien matrisidir ve ağ hatalarının ağırlıklara göre birinci türevlerinden oluşmaktadır. Jakobien matrisi,

$$J = \begin{bmatrix} \frac{\partial e_1}{\partial w_1} & \frac{\partial e_1}{\partial w_2} & \dots & \frac{\partial e_1}{\partial w_N} \\ \frac{\partial e_2}{\partial w_1} & \frac{\partial e_2}{\partial w_2} & \dots & \frac{\partial e_2}{\partial w_N} \\ \dots & \dots & \dots & \dots \\ \frac{\partial e_p}{\partial w_1} & \frac{\partial e_p}{\partial w_2} & \dots & \frac{\partial e_p}{\partial w_N} \end{bmatrix} \quad (20)$$

olarak verilir. Hessian matrisine göre hesaplanması daha kolay olduğu için kullanılması tercih edilmektedir. Ağırlık gradyeni ise;

$$g(k) = J^T(k)e(k) \quad (21)$$

bağıntısıyla elde edilir. Böylece Levenberg-Marquardt algoritması için ağırlık değişim bağıntısı;

$$w(k+1) = w(k) - [J^T(k)J(k) + \mu(k)I]^{-1} J^T(k)e(k) \quad (22)$$

olarak tanımlanır. Bağlıdaki Marquardt parametresi olan μ skaler bir sayıdır. Eğer μ sıfır olursa bu yöntem Newton algoritması, eğer μ büyük bir sayı ise küçük adımlı gradyent azalması algoritması haline gelir. (Ham ve Kostanic, 2000)

Momentum terimli geriye yayılım algoritması ise standart geriye yayılım algoritmasına uygulanan en popüler iyileştirmedir. Bu yöntemde ağırlıklar mevcut performans kriterinin gradyentlerinin toplamına ilave olarak önceki adımda bulunan değeri de kullanır. Ağırlıklar (23) denkleminde verildiği şekilde hesaplanır.

$$\Delta w_{ji}^{(s)}(k+1) = -\mu^{(s)} \frac{\partial E_q}{\partial w_{ji}^{(s)}} + \alpha \Delta w_{ji}^{(s)}(k-1) \quad (23)$$

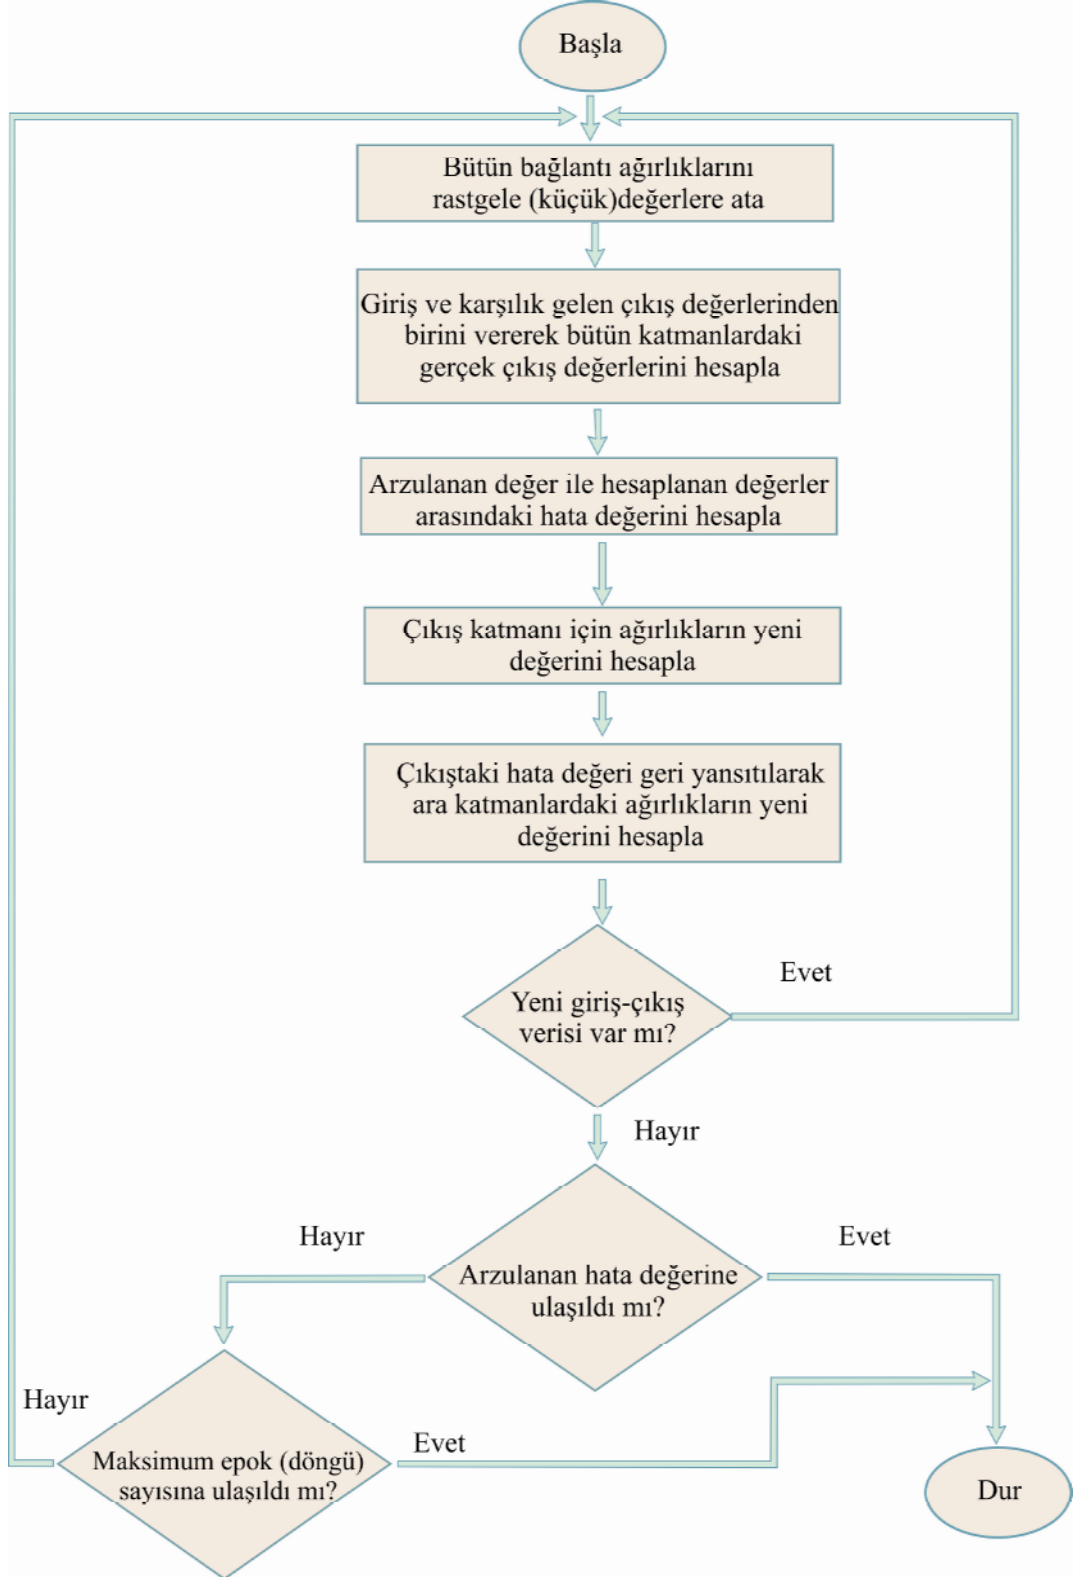
Burada α momentum katsayısı olarak tanımlanır. (Ham ve Kostanic, 2000)

2.1.1.1 Öğrenme ve Momentum katsayıları

Öğrenme katsayısı ağırlıkların değişim miktarını belirlemektedir. Öğrenme katsayısı ne kadar küçük olursa bir iterasyondan diğerine ağırlıklar arasındaki değişim de o kadar küçük olur. Bu nedenle öğrenme hızı da daha yavaş olmaktadır. Öğrenme katsayısının çok büyük olması durumunda ağırlıklar arasındaki değişim de çok büyük olacağından ağ duraysız bir hal alır. Bu dengesiz durumdan kaçınmak için delta kuralına momentum terimi eklenmiştir.

Momentum katsayısı bir önceki iterasyondaki değişiminin belirli bir miktarının yeni değişime eklenmesidir. Yerel çözümlere takılan ağlarda daha iyi sonuçların elde edilmesi amacıyla kullanılmaktadır. Momentum katsayısının küçük seçilmesi yerel çözümden kurtulmayı sağlamayabilir. Büyük değerlerde ise tek bir çözüme ulaşmak mümkün olmayabilir (Haykin, 1999).


Şekil 2.2 de çok katmanlı algılayıcı için akış diyagramı verilmektedir. Bu diyagramda işlem adımları ve ağıın çalışma süreci özetlenmiştir.



Şekil 2.2 Çok katmanlı algılayıcı için geri yayılım akış diyagramı.

2.2 Radyal Taban Fonksiyonlu Ağlar (RTFA)

Radyal Taban Fonksiyonlu ağlar (RTFA) öğretmenli öğrenme temeline dayanır. Birçok araştırmacı tarafından Çok katmanlı Algılayıcı'ya alternatif olarak önerilmektedir. ÇKA'ya göre çok daha kısa sürede öğrenme setini öğrenmektedir. RTFA genel olarak ileri besleme ağ yapısındadır. Dış çevreyi ağa bağlayan bir girdi katmanı, bir gizli katman ve bir doğrusal çıktı katmanı olmak üzere 3 katmandan oluşmaktadır. Ağ yapısı Şekil 2.3 de görülmektedir. Bu ağ türü sınıflama ve fonksiyon yaklaşımı gibi alanlarda yaygın olarak uygulanmaktadır.



Şekil 2.3 Radyal Taban Fonksiyonlu ağ yapısı.

RTFA'nın temeli 1985 yılında Powell tarafından yapılan çalışmaya dayanmaktadır. Powell (1985) çalışmasında düzensiz olarak dağıtılan noktaların RTFA ile çok değişkenli interpolasyonunu göstermiştir. Bu alandaki daha güncel çalışma ise Light (1992 b) tarafından yapılmıştır.

Bu ağ türünde kullanılan aktivasyon fonksiyonu genellikle Gaussian dağılıma dayanmakta ve (24) bağıntısıyla ifade edilmektedir.

$$\phi_j(x) = \exp(-x^2 / \sigma^2) \quad (24)$$

Bağıntıdaki σ radyal tabanlı fonksiyonların genişliğini kontrol eden merkez yayılım parametresidir.

RTFA'ın çıktı katmanındaki herhangi bir nöronun çıktısı (25) bağıntısıyla hesaplanmaktadır.

$$y_i = \sum_{j=1}^n w_{ij} \phi_j(\|\mathbf{x} - \mathbf{c}_j\|_2) \quad j = 1, 2, \dots, m \quad (25)$$

Bağıntıda ϕ_j j . nöronun çıktısı, \mathbf{x} girdi vektörü, \mathbf{c}_j j . radyal tabanlı fonksiyonların merkezleri ve $\|\cdot\|_2$ Euclidean normu göstermektedir. Ayrıca w_{ij} gizli katmandaki j nöronunu çıktı katmanındaki i nöronuna bağlayan ağırlıklar ve n ise gizli katmandaki nöron sayısıdır. RTFA'nın eşleme özelliği çıktı katmanındaki ağırlıklar, RTFA'nun merkez vektörleri ve Gaussian fonksiyonunun genişliği ile değiştirilebilir. RTFA ağın en basit eğitim şekli merkezlerin sayılarının sabitlenmesidir. Eğer merkezlerin sayısı girdi vektörünün sayısına eşitlenirse, exact (tam) RTFA olarak isimlendirilir. Bu durumda eğitim seti için istenilen çıktı ve hesaplanan çıktı arasındaki hata sıfır olacaktır.

Kullanılan Gaussian fonksiyonunun genişliği ne kadar küçükse ağın ayrımlılığı o kadar iyi olur. Genişlik büyüdükçe ayrımlılık tersi oranında azalır.

2.3 Çok Katmanlı Algılayıcı (ÇKA) ve Radyal Taban Fonksiyonlu Ağ (RTFA) Arasındaki Farklar

Çok katmanlı algılayıcı ve Radyal taban Fonksiyonlu ağların her ikisi de ileri beslemeli ağlar sınıfında ve genel yaklaşımçı (universal approximator) olsalar da aralarında bazı farklılıklar mevcuttur. Bu farklar en genel haliyle verilirse;

- En temel haliyle RTFA tek gizli katmandan oluşmaktadır. ÇKA ise bir veya birden fazla gizli katmana sahip olabilir.

- Girilen veri seti RTFA ile daha kısa sürede eğitilir. ÇKA ise aynı veri setini eğitmek için daha fazla zamana ihtiyaç duymaktadır.
- RTFA gizli katmandaki nöronlar doğrusal değildir. Ancak çıktı katmanındaki nöronlar doğrusaldır. ÇKA' da ise tüm katmanlarda genellikle doğrusal olmayan nöronlar kullanılır. Eğer ÇKA doğrusal olmayan regresyon analizinde kullanılıyorsa doğrusal çıkış katmanı tercih edilir.
- Doğrusal olmayan girdi-çıkış eşleşmesinde ÇKA RTFA göre daha az parametreye ihtiyaç duymaktadır.


BÖLÜM ÜÇ

UYGULAMALAR

3.1 Gravite Verilerinin Yapay Sinir Ağları ile Değerlendirilmesi

Gravite verilerinin yapay sinir ağları ile değerlendirilmesinde Şekil 3.1’de görülen ÇKA ağ yapısı kullanılmıştır. Teorik olarak hesaplanan gravite değerleri ağın girdisi, yapının derinliği, yoğunluk farkı ve lokasyonu gibi bilgileri içeren model ise ağın çıktısı olacak şekilde ağ eğitilmiştir. Eğitim kümesinde birbirinden farklı model ve bu modellere ait anomaliler kullanılmıştır. Arazi verilerinin modellerini elde etmek için bu anomaliler test amacıyla kullanılmıştır.

Şekil 3.1 de görülen Δg vektörü N noktada ölçülmüş ya da hesaplanmış gravite değerlerini göstermektedir. Gravite modellemesinde her uygulama için nöron sayıları değişen 2 gizli katmandan oluşan ÇKA kullanılmıştır. y Çıktısı ise yapının özelliklerinden oluşan modeli temsil eder.



Şekil 3.1 YSA’ da gravite girdi ve çıktı gösterimi.

Farklı modellerden oluşan eğitim seti ÇKA yapısıyla eğitilerek eğitim setinde bulunmayan farklı modellerle test edilmiştir. Arazi uygulamalarında arazide gözlenen değerler test amacıyla kullanılmıştır. ÇKA çalışma adımları sırasıyla aşağıda verilmektedir.


- Öncelikle girdi ve çıktı setleri belirlenir. Gravite uygulaması için Δg ile gösterdiğimiz gravite değerleri ağıımızın girdisi, bu gravite anomalisine neden olan yapının parametrelerini gösteren model ise çıktı olarak seçilmiştir. Yapı parametre modeli, yapının derinliği, yoğunluk farkı ve bulunduğu lokasyon bilgilerini içermektedir.
- Ağı eğitmek için gerekli olan parametreler, katmanlardaki nöron sayısı, gizli katman sayısı, öğrenme ve momentum katsayıları ve istenilen hata değeri ile epok sayıları sisteme verilir. Bu parametreler seçilirken belli bir kural yoktur. Deneme yanılma yoluyla problemimize en iyi sonucu veren parametreler bulunur. Sistemin eğitilmesinde geri yayılım algoritması kullanılmıştır. Burada elde edilen çıktı değerleri ağıın gravite girdilerimize karşılık bize vermiş olduğu çıktılardır. Eğitim setinde vermiş olduğumuz çıktı ile ağıın hesapladığı çıktı arasındaki hata hesaplanır. Öngörülen hassasiyet elde edilene kadar hata ağıın ağırlık değerlerine dağıtılır ve bir sonraki aşamada hatanın azalması sağlanır. Geri yayılım aşaması ile ilgili bağıntılar ve işlem aşamaları Bölüm 1 de açıklanmaktadır.
- *İleri besleme aşaması:* Bu aşamada birinci katmandaki nöronların değeri sisteme verilen girişlerle karşılık gelen ağırlıkların çarpımlarının toplamına eşittir. Nöron çıktısı aktivasyon fonksiyonundan geçirildikten sonra bir sonraki katmandaki nöronlara yine ağırlıklar yardımıyla bağlanır ve değerleri aynı yöntemle hesaplanır. Aşağıda giriş katmanı için nöronların değeri

$$Net = \sum_{j=1}^N W_{ij} \Delta g_j \quad (26)$$

bağıntısıyla verilir. buradaki Δg ifadesi N noktada ölçülmüş yada hesaplanmış gravite değerlerini, W girdi ile nöronlar arasındaki ağırlık değerlerini göstermektedir. Bu parametrelere ait bağıntılar Bölüm 1’ de 6 ve 7 eşitlikleri ile tanımlanmıştır. Böylece her nöron hücresine gelen girdilerin ağırlıklarla çarpımının toplamından oluşan net girdi hesaplanmış olur. Bu işlem ağda bulunun bütün nöron hücreleri için hesaplanır.

- Hesaplanan net girdi aktivasyon fonksiyonundan geçirilerek diğer gizli katmandaki nöron hücresinin girdisi oluşturulmuş olur. Bu çalışmada logaritmik sigmoid ve hiperbolik tanjant aktivasyon fonksiyonları

kullanılmıştır. Bu fonksiyonlar türevleri alınabilir olması ve türev işleminin kolay hesaplanması nedeniyle tercih edilmiştir. Aktivasyon fonksiyonlarının matematiksel ifadesi Bölüm 1 de 1 ve 4 bağıntıları ile tanımlanmaktadır. Çıktı katmanında elde edilen değerler ağıımızın hesapladığı çıkış değerleridir. Çıkış değerlerinin hesaplanmasıyla ileri besleme aşaması son bulur.



Şekil 3.2 YSA eğitim eğrileri.

Ağ eğitim süreci kullanıcı tarafından belirlenen hata değerine yada sisteme girilen epok (döngü) değerine ulaşınca kadar devam eder. Şekil 3.2 (a) da görülen eğitim eğrisinde sistem istenilen performans değerine 8047 epokta ulaşmış ve girilen epok sayısı bitmeden eğitim süreci sona ermiştir. Şekil 3.2 (b) de görülen eğitim eğrisinde ise sistem istenilen performans değerine ulaşamamış ancak girilen epok sayısına ulaşıldığı için eğitim süreci sonlanmıştır. Eğitim sürecinin bitmesiyle sisteme girilen test verileri sistemin performansını analiz etmek amacıyla kullanılır.

3.1.1 Kuramsal Modeller

Yapay sinir ağlarının gravite yöntemindeki uygulanabilirliği öncelikle birbirinden farklı birçok kuramsal model üzerinde test edilmiştir. Oluşturulan modeller ve uygulamalar aşağıda sırasıyla verilmektedir.

3.1.1.1 Nokta Kütle ve Küre

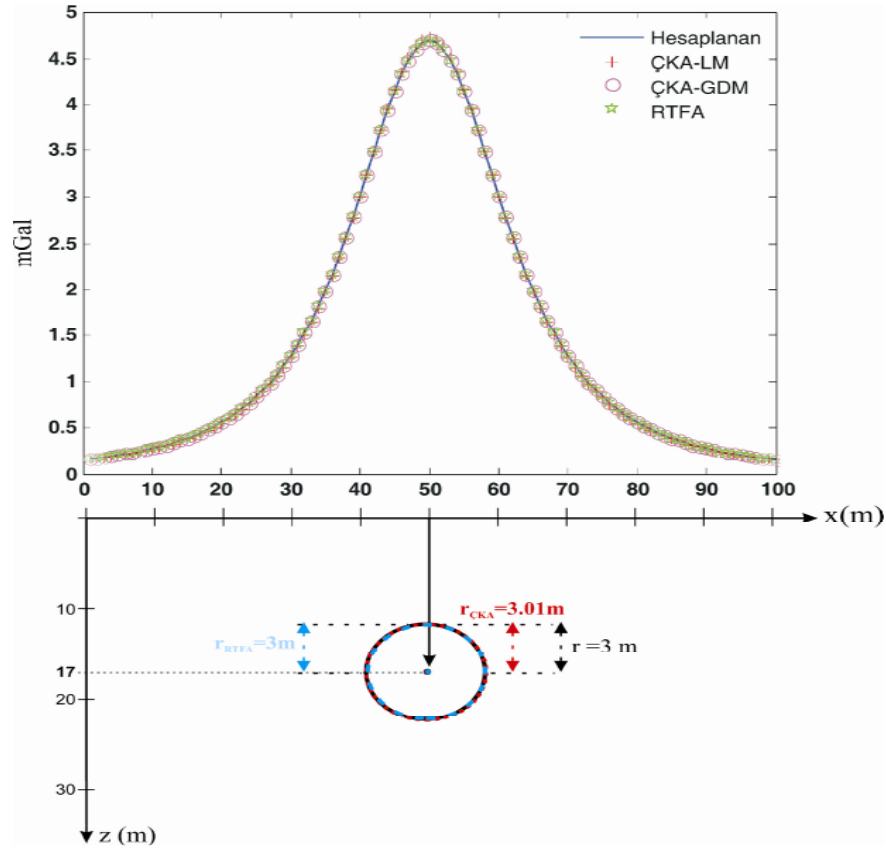
Kütlesi m olan homojen bir kürenin dışındaki bir noktaya uyguladığı çekim kuvveti, kürenin merkezinde bulunan ve kütlesi m olan nokta kütlelerin aynı noktaya uyguladığı kuvvete eşittir.

$$\Delta g = \frac{G.m.z}{(x^2 + z^2)^{3/2}} \quad (27)$$

Bağıntıda $G=6.672.10^{-8} \text{ cm}^3/\text{gsn}^2$ gravitasyon sabiti, m ; yapının kütlesi ve z ; yapının derinliği olarak verilmektedir.

(27) bağıntısı kullanılarak kuramsal gravite anomalileri oluşturulmuştur. Bu anomaliler yapay sinir ağları yöntemi ile değerlendirilmiştir. Oluşturulan anomaliler girdi, yapının derinliği, yoğunluğu, lokasyonu ve yarıçapı çıktı olacak şekilde oluşturulan eğitim seti ile ağ eğitilmiştir. Eğitim setinin dışında kalan farklı modellerle ağın performansı test edilmiştir. Eğitimin setinde birbirinden farklı otuzbeş model bulunmaktadır. Her modelde kürenin yarıçapı ve yoğunluğu dolayısıyla kütlesi, derinliği ve kürenin bulunduğu yer farklıdır. Çeşitli denemelerden sonra gizli katmanlarında 30 ve 20 nöron bulunan ÇKA kullanılmıştır. Öğrenme ve momentum katsayıları 0,4 and 0,7 için en iyi sonuç elde edilmiştir. Test setinde modelin derinliği 17 m, yoğunluğu ise $1,8 \text{ gr/cm}^3$ olarak verilmiştir. ÇKA için elde edilen derinlik ve yoğunluk sonuçları 17 m ve 1.79 gr/cm^3 tür.

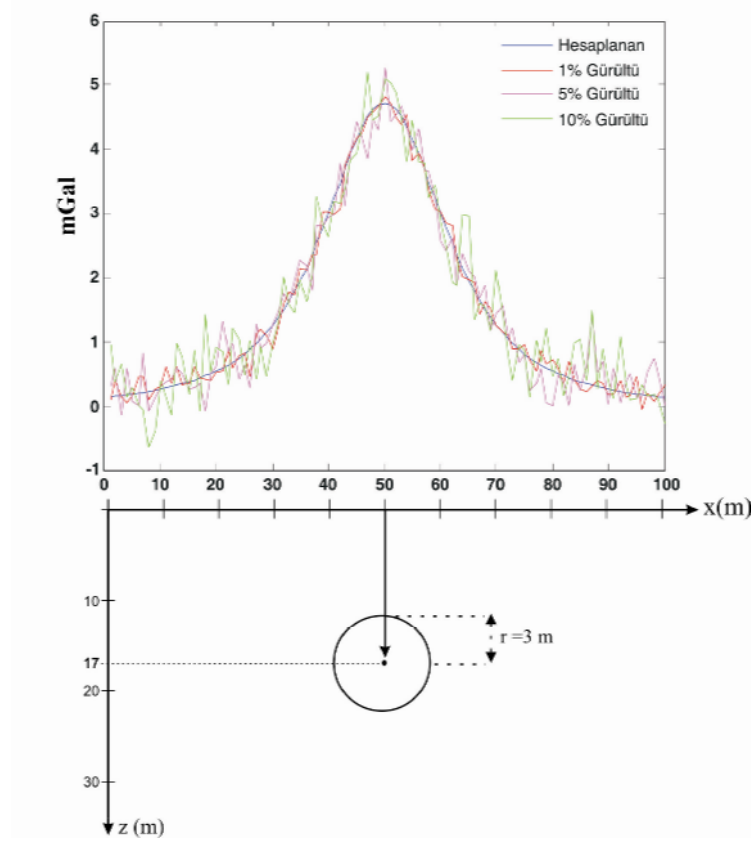
Aynı model RTFA ile de test edilmiştir. Bilindiği gibi RTFA tam dizayn için eğitim seti hatası sıfır olarak alınır. Test için derinlik ve yoğunluk değerleri sırasıyla 17 m ve $1,8 \text{ gr/cm}^3$ olarak saptanmıştır. Elde edilen tüm sonuçlar Şekil 3.3 ve Tablo 3.1 de görülmektedir.



Şekil 3.3 Nokta kütle ve küre modeli için elde edilen yapay sinir ağı sonuçları.

3.1.1.2 Nokta Kütle ve Küre Anomalisi Üzerinde Random Gürültünün Etkisi

Bir önceki kullanılan test verisi YSA' nın gürültülü verilerdeki performansını test etmek amacıyla %1, 5 ve 10 oranlarında rastgele Gaussian gürültü eklenerek test edilmiştir. Eklenen değişik orandaki gürültülü gravite anomalileri Şekil 3.4 de görülmektedir. Önceki aşamada kullanılan ağı gizli katman ve katmanlarda bulunan nöron sayıları ile öğrenme ve momentum katsayıları bu aşamada da aynı alınmıştır. Her gürültü oranı için ÇKA ve RTFA sonuçları Tablo 3.1 de görülmektedir



Şekil 3.4 Eklenen değişik orandaki gürültüler.


Tablo 3.1 incelendiğinde eklenen gürültünün oranı arttıkça elde edilen parametrelerdeki hata oranının da arttığı gözlenmektedir.

Tablo 3.1 Kuramsal nokta kütle ve küre modeli için eklenen değişik orandaki gürültülerin YSA sonuçları.

		Derinlik (m)	Yoğunluk (gr/cm ³)	Yarıçap (m)	Lokasyon (m)	Derinlik M. Hata	Yoğunluk Hata	Yarıçap M.Hata	Lokasyon M. Hata
Ç K A	MODEL	17	1,8	3	50	-	-	-	-
	Gürültüsüz	17	1,79	3,01	49,95	0	0,01	0,01	0,05
	%1 Gürültülü	16,8	1,78	3,03	50,25	0,2	0,02	0,03	0,25
	%5 Gürültülü	16,8	1,78	2,95	49,73	0,2	0,02	0,05	0,27
R T F A	% 10 Gürültülü	16,7	1,77	3,1	50,45	0,3	0,03	0,1	0,45
	Gürültüsüz	17	1,8	3	50	0	0	0	0
	%1 Gürültülü	17	1,79	3,03	50,3	0	0,01	0,03	0,3
	%5 Gürültülü	17,1	1,78	3,05	50,4	0,1	0,02	0,05	0,4
	% 10 Gürültülü	17,2	1,77	3,1	50,6	0,2	0,03	0,1	0,6

3.1.1.3 İki Boyutlu Kuramsal Modeller

İki boyutlu kuramsal modeller oluşturulurken bilinen bir geometriden yola çıkarak meydana gelecek gravite anomalisi hesaplanmıştır. Bu amaçla yer altı Şekil 3.5 de görüldüğü gibi dikdörtgenlere bölünerek her dikdörtgene modelin geometrisine uygun yoğunluk değerleri atanmıştır. Yoğunluk değerleri atanırken katmanlar arası yoğunluk farkı kuramına uyulmuştur.



Şekil 3.5 İki boyutlu model.

Şekil 3.5 de görülen i noktası için gravite bağıntısı;

$$g_i = \sum_{j=1}^M a_{ij} v_j + e_i, \quad i = 1 \dots N \quad (28)$$

olarak verilmektedir. $v_j = j$. bloğun yoğunluğu, $e_i = i$. nokta ile ilişkili gürültü; $a_{ij} = j$. bloğun i . gravite değeri üzerindeki etkisini gösteren matris aşağıdaki gibi ifade edilebilir.

$$a_{ij} = 2G \left[(x_i - x_j + d/2) \log(r_2 r_3 / r_1 r_4) + d \log(r_4 / r_3) - (z_j + h/2)(\theta_4 - \theta_2) + (z_j - h/2)(\theta_3 - \theta_1) \right] \quad (29)$$

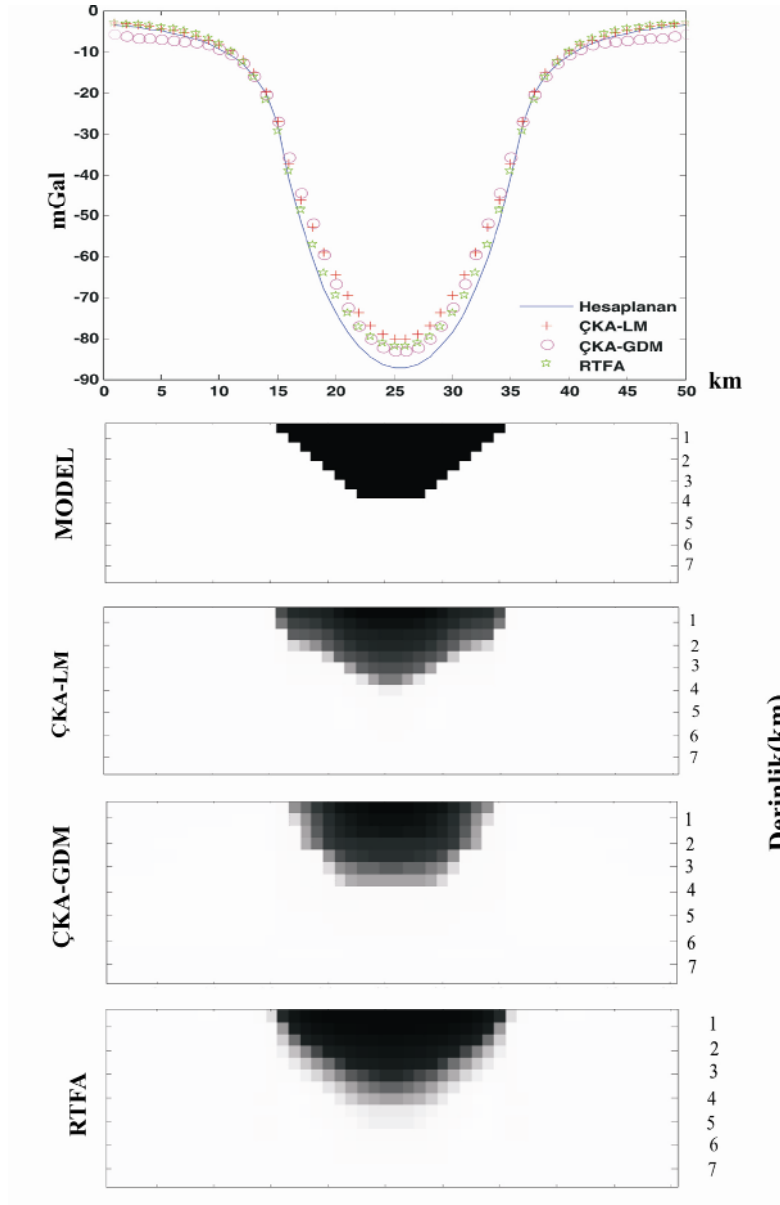
$$\begin{aligned} r_1^2 &= (z_j - h/2)^2 + (x_i - x_j + d/2)^2 \\ r_2^2 &= (z_j + h/2)^2 + (x_i - x_j + d/2)^2 \\ r_3^2 &= (z_j - h/2)^2 + (x_i - x_j - d/2)^2 \\ r_4^2 &= (z_j + h/2)^2 + (x_i - x_j - d/2)^2 \end{aligned} \quad (30)$$

$$\begin{aligned}
\theta_1 &= \arctan(x_i - x_j + d/2)/(z_j - h/2) \\
\theta_2 &= \arctan(x_i - x_j + d/2)/(z_j + h/2) \\
\theta_3 &= \arctan(x_i - x_j - d/2)/(z_j - h/2) \\
\theta_4 &= \arctan(x_i - x_j - d/2)/(z_j + h/2)
\end{aligned} \tag{31}$$

G gravite sabitidir (Last ve Kubik, 1983).

3.1.1.3.1 Graben Modeli: Kuramsal graben modeli Last ve Kubik, 1983 te olduğu gibi iki boyutlu modelin yatay ve düşey dikdörtgen bloklara bölünmesiyle oluşturulmuştur. Bloklar uygun jeoloji ve istenilen yapı şekline göre farklı yoğunluk değerlerine sahiptir. Derinliği, yoğunluk farkı, lokasyonu ve şekli farklı kırk değişik model, ağı eğitmek amacıyla oluşturulmuştur. Hesaplanan anomaliler girdi, model ise çıktı olacak şekilde ağa sunulmuştur. İlk katmanda 8 ikinci katmanda 5 nöron bulunan ÇKA en iyi sonucun elde edildiği yapı olmuştur. Veriler [-1 1] aralığında normalize edilmiş ve hiperbolik tanjant aktivasyon fonksiyonu kullanılmıştır. Öğrenme katsayısı 0,5 momentum katsayısı ise 0,9 olarak seçilmiştir. Ağı test etmek amacıyla oluşturulan eğitim seti dışındaki modelin yoğunluğu ve derinliği sırasıyla 2,3 gr/cm³ ve 4 km' dir. Bulunan sonuçlar ÇKA-GDM için 2,32 gr/cm³ ve 4 km' dir. ÇKA-LM için ise 2,35 gr/cm³ ve 4 km' dir.


Aynı test verisi RTFA sonuçları ise 2,33 gr/cm³ ve 4 km dir. Oluşturulan model ve yapay sinir ağı sonuçları Şekil 3.6 da görülmektedir.



Şekil 3.6 Kuramsal graben modeli ve yapay sinir ağı sonuçları.

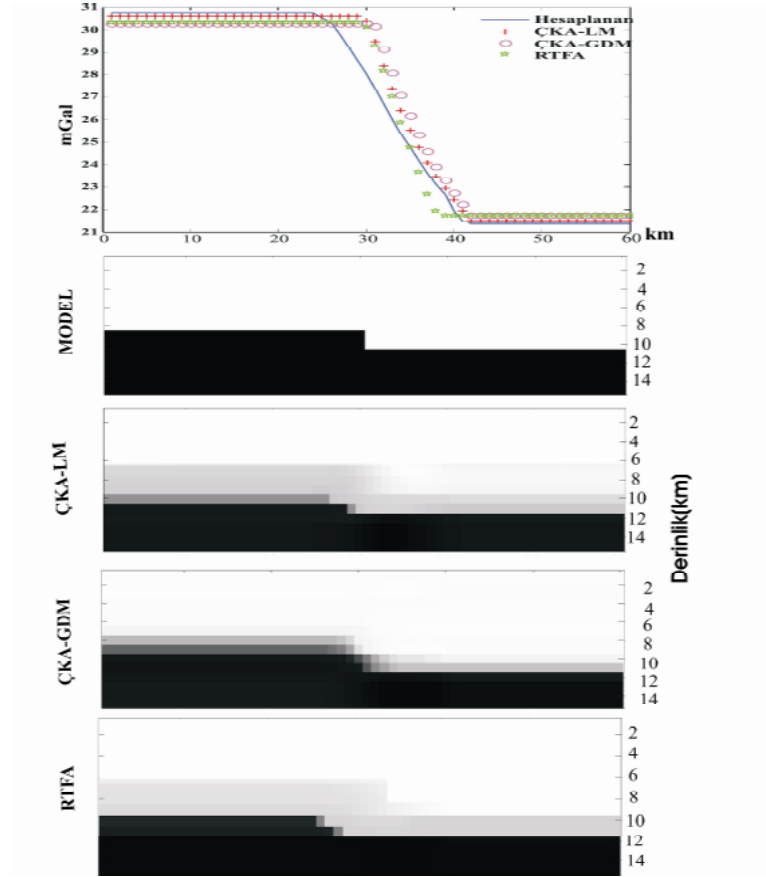
3.1.1.3.2. *Dayk Modeli:* Kuramsal graben modelinde olduğu gibi yer altı modeline uygun yoğunluk farkına sahip 45 farklı model ağı eğitmek amacıyla oluşturulmuştur. Modellerin yoğunluk farkları, derinlikleri, lokasyonları ve şekilleri birbirinden farklıdır. Birinci ve ikinci gizli katmanlarında sırasıyla 5 ve 3 nöron bulunan ÇKA kullanılmıştır. Öğrenme katsayısı ve momentum katsayıları 0,4 ve 0,7 olarak seçilmiştir. Test verisinde yoğunluk ve derinlik $2,6 \text{ gr/cm}^3$ ve 3 km dir. ÇKA-LM için elde edilen yoğunluk ve derinlik değerleri $2,58 \text{ gr/cm}^3$ ve 3 km' dir. ÇKA-GDM için ise elde edilen sonuçlar sırasıyla $2,63 \text{ gr/cm}^3$ ve 3 km dir.

Aynı test verisi için RTFA sonuçları ise $2,63 \text{ gr/cm}^3$ ve 3 km ' dir. Oluşturulan model ve yapay sinir ağları sonuçları Şekil 3.7 de görülmektedir.



Şekil 3.7 Kuramsal dayk modeli ve yapay sinir ağı sonuçları.

3.1.1.3.3.Basamak Modeli: Daha önceki aşamalarda oluşturulan kuramsal modellerde olduğu gibi yer altı modeline uygun yoğunluk farkına sahip otuzsekiz farklı model ağı eğitmek amacıyla kullanılmıştır. Modellerin yoğunluk farkları, derinlikleri, lokasyonları ve şekilleri birbirinden farklıdır. Birinci ve ikinci gizli katmanlarında sırasıyla 5 ve 3 nöron bulunan ÇKA kullanılmıştır. Öğrenme katsayısı ve momentum katsayısı sırasıyla 0,4 ve 0,7 olarak seçilmiştir. Test verisinde modelin yoğunluğu $2,65 \text{ gr/cm}^3$, basamağın üst ve alt bölümlerinin derinlikleri sırasıyla 9 ve 11 km'dir. ÇKA GDM için elde edilen derinlik ve yoğunluk değerleri 9-11 km ve $2,63 \text{ gr/cm}^3$ tür. ÇKA LM için sonuçlar ise derinlikler yaklaşık 10-11 km, yoğunluk ise $2,64 \text{ gr/cm}^3$ dir. Aynı modelin RTFA sonuçları, yoğunluk $2,63 \text{ gr/cm}^3$ derinlik ise 10-11 km' dir. Elde edilen tüm sonuçlar ve modeller Şekil 3.8 de görülmektedir.



Şekil 3.8 Kuramsal basamak modeli ve yapay sinir ağı sonuçları.


Kuramsal modellerin tümü için elde edilen ÇKA ve RTFA sonuçları Tablo 3.2 de verilmektedir.

Tablo 3.2 Kuramsal modeller ve yapay sinir ağı sonuçları.

		Derinlik (km)	Yoğunluk (gr/cm ³)	Derinlik Mutlak Hata	Yoğunluk Mutlak Hata
Ç K A	DAYK(MODEL)	3	2,6	-	-
	ÇKA-LM	3	2,58	0	0,03
	ÇKA-GDM	3	2,63	0	0,02
	RTFA	3	2,63	0	0,03
ve	GRABEN(MODEL)	4	2,3	-	-
	ÇKA-LM	4	2,35	0	0,05
	ÇKA-GDM	4	2,32	0	0,02
	RTFA	4	2,33	0	0,03
R T F A	BASAMAK(MODEL)	9-11	2,65	-	-
	ÇKA-LM	10-11	2,64	1-0	0,01
	ÇKA-GDM	9-11	2,63	0	0,02
	RTFA	10-11	2,63	1-0	0,02

3.1.1.4 Kuramsal İki Farklı Yapıdan Oluşan Modeller

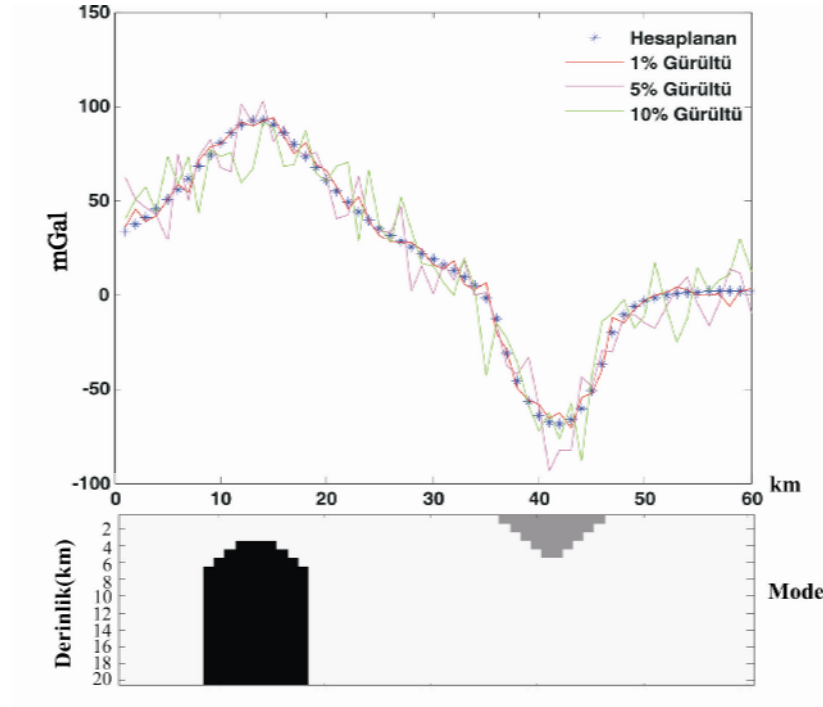
Modeller geometrik açıdan farklı graben, dayk ve küre gibi modellerin ikisinin birleşiminden oluşturulmuştur. Eğitim setinde lokasyonları, yoğunluk farkları, derinlikleri ve geometrik şekilleri farklı kırkbeş model bulunmaktadır. Hesaplanan anomaliler girdi, model çıktı olacak şekilde ağ eğitilmiştir. 8 ve 5 nörondan oluşan, öğrenme katsayısı 0,4 momentum katsayısı ise 0,9 olan ÇKA ve RTFA kullanılmıştır. ÇKA LM ile dayk için derinlik ve yoğunluk değerleri 4 km ve 2,82 gr/cm³, graben için değerler 4 km ve 2,18 gr/cm³ olarak saptanmıştır. ÇKA GDM için daykın derinlik ve yoğunluğu 4 km ve 2,83 gr/cm³, grabenin ise 4 km ve 2,19 gr/cm³ olarak bulunmuştur. RTFA uygulamasında dayk için derinlik ve yoğunluk değerleri 4 km ve 2,78 gr/cm³, graben için ise 4 km ve 2,2 gr/cm³ olarak saptanmıştır.



Şekil 3.9 Kuramsal model ve yapay sinir ağı sonuçları.

3.1.1.5 Kuramsal İki Farklı Yapıdan Oluşan Modellerde Gürültünün Etkisi

Bir önceki aşamada oluşturulan eğitim seti gürültü test verisinin YSA'nın gravite uygulamalarındaki etkisini incelemek amacıyla kullanılmıştır. Eğitim seti 45 modelden oluşmakta aynı test verisine %1, 5 ve 10 oranlarında rastgele Gaussian gürültü eklenerek YSA'nın performansı test edilmiştir. Eklenen değişik orandaki gürültüler Şekil 3.10 de görülmektedir.



Şekil 3.10 Eklenen değişik orandaki gürültüler

Gürültülü verilerin eğitimi aşamasında 8 ve 5 nörondan oluşan iki katmanlı ÇKA yapısı kullanılmıştır. Öğrenme ve momentum katsayıları 0,5 ve 0,9 olarak seçilmiştir. % 1 gürültü oranı için ÇKA LM ve ÇKA GDM için Tablo 3.3 te görülen derinlik ve yoğunluk değerleri elde edilmiştir. % 5 gürültü oranı için ÇKA LM ve ÇKA GDM ile elde edilen derinlik ve yoğunluk farkı değerleri Tablo 3.3 te verilmektedir. % 10 gürültü eklenmiş veri için ÇKA LM ve ÇKA GDM için elde edilen derinlik ve yoğunluk değerleri Tablo 3.3 te verilmektedir. Ayrıca RTFA aynı veri setine uygulanmış ve elde edilen derinlik ve yoğunluk farkı değerleri Tablo 3.3 te görülmektedir.

Tablo 3.3 Eklenen deęişik orandaki gürültüler için yapay sinir aęları ile elde edilen sonuçlar.

		Derinlik (km)	Yoęunluk (gr/cm ³)	Derinlik Mutlak Hata	Yoęunluk Mutlak Hata
Ç K A	DAYK	4	2,8	-	-
	Gürültüsüz	4	2,82	0	0,02
	%1 Gürültülü	4	2,83	0	0,03
	%5 Gürültülü	4	2,84	0	0,04
	% 10 Gürültülü	4,5	2,86	0,5	0,06
	GRABEN	4	2,2	-	-
	Gürültüsüz	4	2,18	0	0,02
	%1 Gürültülü	4	2,17	0	0,03
	%5 Gürültülü	4	2,17	0	0,03
	% 10 Gürültülü	3,5	2,15	0,5	0,05
R T F A	DAYK	4	2,8	-	-
	Gürültüsüz	4	2,78	0	0,02
	%1 Gürültülü	4	2,82	0	0,02
	%5 Gürültülü	4	2,83	0	0,03
	% 10 Gürültülü	4,5	2,75	0,5	0,05
	GRABEN	4	2,2	-	-
	Gürültüsüz	4	2,2	0	0
	%1 Gürültülü	4	2,17	0	0,03
	%5 Gürültülü	4	2,17	0	0,03
	% 10 Gürültülü	3,5	2,15	0,5	0,05

Tablo 3.3 incelendięinde gürültü oranı arttıkça elde edilen derinlik ve yoęunluk deęerlerindeki hata oranının da arttıęı görölmektedir. Gürültü oranlarına göre mutlak hata deęerleri derinlikler için 0 ve 0,5 yoęunluklar için ise 0,02-0,06 arasında deęişmektedir.

3.1.2 Yapay Sinir Ağlarının Jeofizik Verilere Uygulanması

Çalışma alanı olan Batı Türkiye Bouguer gravite verileri (Maden Tetkik ve Arama (MTA), 1979) ve sismoloji katalog verileri (Boğaziçi Üniversitesi Kandilli Rasathanesi ve TC Bayındırlık ve İskan Bakanlığı Afet İşleri Genel Müdürlüğü Deprem Araştırma Dairesi) Yapay sinir ağları ile değerlendirilmiştir. Bölgenin en temel karakteristik özelliği olan grabenler üzerinden alınan gravite kesitleri ÇKA ve RTFA ile yorumlanarak tortul kalınlığı ve yoğunluk farkı elde edilmiştir. Sismolojik katalog verileri aylık deprem frekansları derlenerek ÇKA ve RTFA ile değerlendirilip deprem aylık oluş sayılarının ön kestirimi yapılmıştır.

3.1.2.1 Batı Türkiye'nin Tektoniği

Batı Türkiye'nin aktif tektoniği, Anadolu'nun sağ yanal Kuzey Anadolu (KAF) ve sol yanal Doğu Anadolu (DAF) doğrultu atımlı fay zonları boyunca batıya kaçıışı, Yunanistan'ın batısındaki kıtasal kalınlaşmadan dolayı Anadolu'nun batıya kaçışının engellenmesi kuzey ve orta Ege bölgesinde doğu-batı sıkışmanın meydana gelmesi ve bunun sonucunda Batı Anadolu'nun saatin tersi yönünde dönerek güneybatı yönünde Hellenik yayın üzerine doğru hareketiyle açıklanmaktadır. (Dewey ve Şengör, 1979; Le Pichon ve Angelier, 1979, 1981; McClusky ve diğer., 2000 McKenzie, 1972, 1978; Şengör ve diğer., 1985). Bölgenin güncel tektoniğini kontrol eden ana yapılar Şekil 3.11 de görülmektedir.

Bölgedeki D-B yönlü sıkışma sonucu yaklaşık K-G yönlü genişleme tektoniği meydana gelmektedir. Genişlemenin oluşumu konusunda üç farklı görüş öne sürülmektedir.



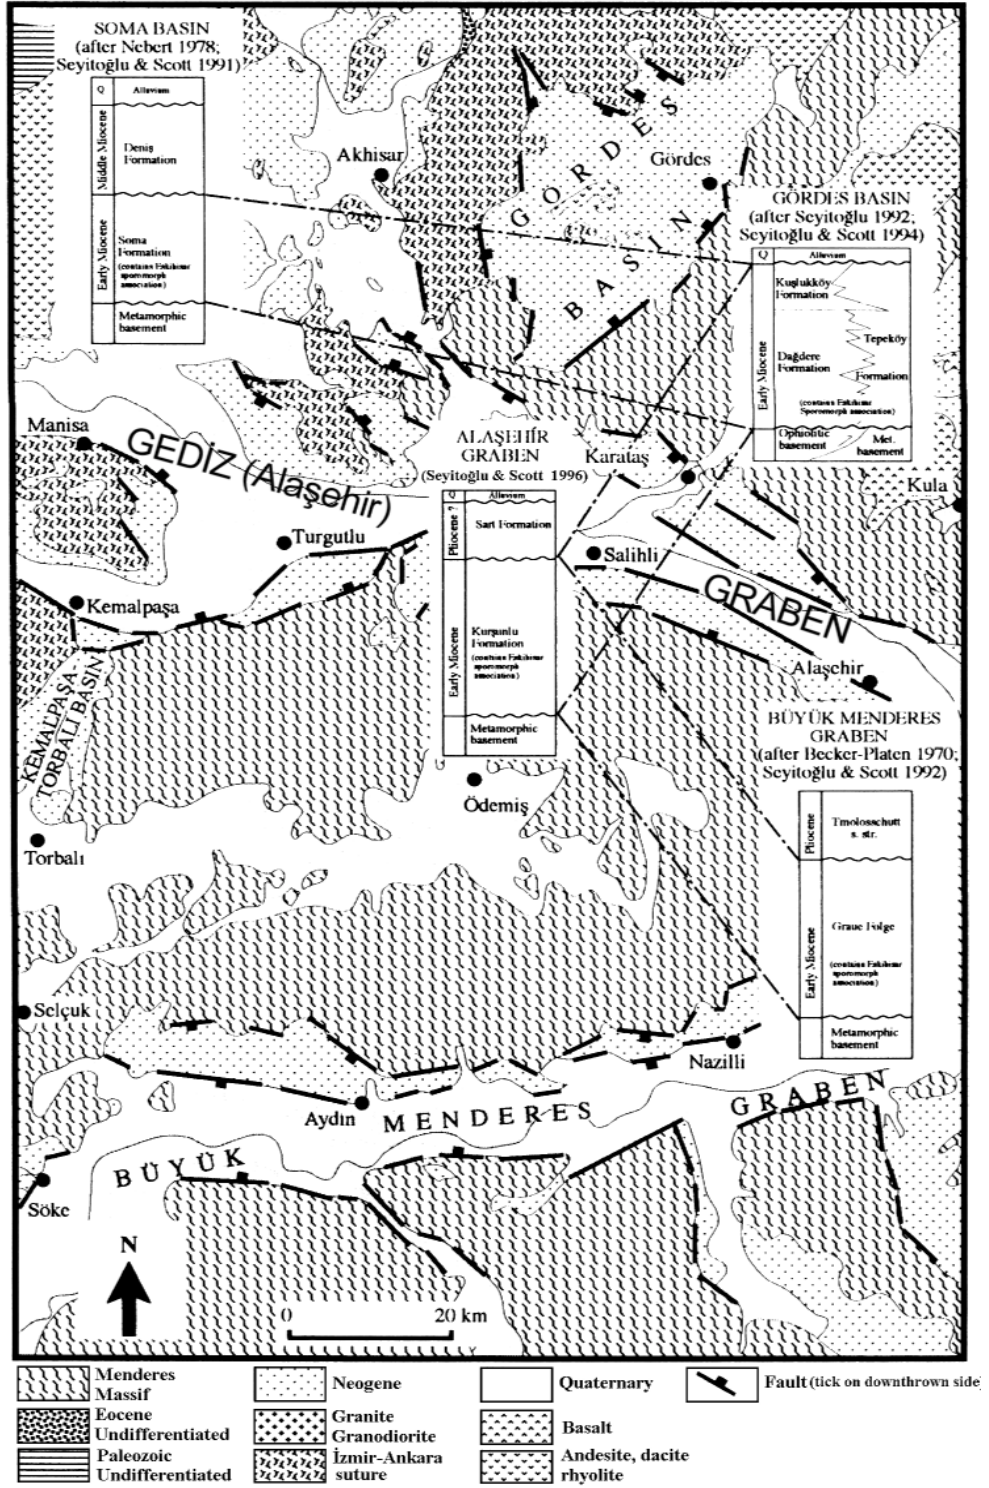
Şekil 3.11 Batı Anadolu'nun güncel tektoniğini kontrol eden ana yapılar (Okay ve diğer., 2000).

- *Tektonik Kaçış:* Bu görüşe göre Anadolu levhası geç Serravalian zamanı boyunca Arap ve Avrasya levhalarının çarpışmasının etkisiyle gelişen Doğu Anadolu ve Kuzey Anadolu fayları boyunca batıya doğru hareket etmiştir. Anadolu levhasının B-GB yönlü tektonik kaçışı, Batı Anadolu' da açılma tektoniği ile açıklanan horst-graben yapılarının gelişmesine neden olmuştur (Dewey ve Şengör, 1979; Şengör, 1979, 1980, 1987; Şengör ve diğer., 1985).
- *Yay ardı genişleme:* Bu genişleme görüşüne göre Hellenik Trench sisteminin G-GB yönlü hareketi, yay ardı genişlemeye ve horst-graben sisteminin oluşmasına neden olmuştur (LePichon ve Angelier, 1979; Meulenkamp ve diğer., 1988).
- *Orojenik Çökme:* Dağ kuşaklarının kendi ağırlıkları nedeniyle yanal olarak yayılması ve çökmesidir. (Dewey, 1988; Seyitoğlu ve Scott, 1992, 1996).
- *Epizodik Grabenleşme Modeli:* iki evreli graben oluşum modelidir. Bu modele göre Batı Anadolu' daki grabenleşme iki farklı çekme tektoniği rejimi altında gelişmiştir. Miyosen- erken Pliyosen ilk evre orojenik çökme

nedeniyle graben oluşumu, pliyokuvaterner ikinci evre Anadolu bloğunun batıya doğru kaçması sonucu oluşan K-G yönlü gerilme olarak açıklanmaktadır (Bozkurt, 2000; Koçyiğit ve diğer., 1999, 2000).

Genişleme tektoniğine bağlı olarak Batı Türkiye’de D-B ve BKB-DGD doğrultulu birçok graben gelişmiştir (Dewey ve Sengör 1979; Jackson ve McKenzie 1984; Ketin 1968; McKenzie, 1978; Sengör 1982, 1987; Sengör ve diğer., 1984). En önemlileri Gediz, Büyük Menderes ve Küçük Menderes’dir. Bu bölgeler D-B doğrultulu atımlı faylarla sınırlanmış birçok bloklardan meydana gelmektedir. Bölgede K-G ve GB-KD yönlü genişleme tektoniğinin etkisiyle gelişen D-B, KD ve KB gidişli faylar (Koçyiğit, 1984; Koçyiğit ve diğer., 2000), Batı Türkiye’de depremsellik açısından en aktif fay sistemini meydana getirmektedir. Bölgedeki temel grabenler ve jeolojik birimler Şekil 3.12’de görülmektedir.

Ayrıca bölgede yapılan GPS ölçümleri Batı Türkiye’deki güncel genişlemenin daha çok KD-GB yönünde olduğunu göstermektedir. Ege bölgesinin güney bölümünde GB’ya doğru yıllık genişleme hızının 30 mm’ye ulaştığı gözlenmektedir (McClusky ve diğer., 2000; Şalk ve diğer., 1999).

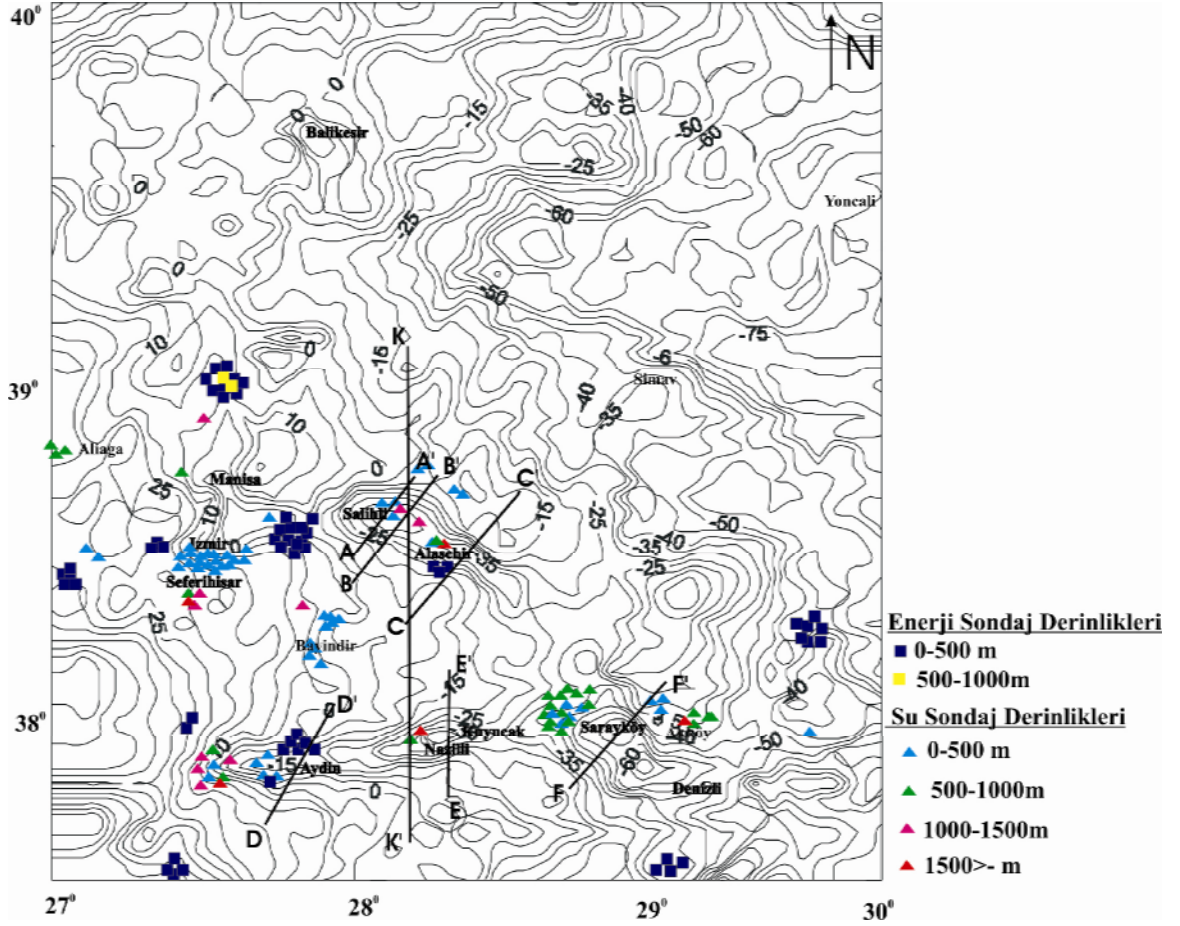


Şekil 3.12 Gediz ve Büyük Menderes Grabenlerinin jeoloji ve tektoniği (Seyitoğlu ve Scott, 1996).

3.1.2.2 Batı Türkiye Gravite Verileri

Çalışmada MTA tarafından yayınlanan 1/ 500.000 ölçekli Bouguer gravite anomali haritası kullanılmıştır (MTA, 1979). Grabenler üzerinde tortul kalınlığının fazla olması ve düşük yoğunluk değerlerinden dolayı düşük gravite değerleri görülmektedir. Horstların olduğu bölgelerde ise Menderes masifinin metamorfik kayalarından dolayı daha yüksek gravite değerleri gözlenmektedir. Çalışma alanı olan D-B doğrultulu Gediz ve Büyük Menderes grabenleri negatif Bouguer anomali değerlerinin gözleendiği geniş alanlardır. Şekil 3.13' de görülen Bouguer anomali haritası incelendiğinde Gediz grabeni boyunca Salihli ve Alaşehir bölgelerinde ve Büyük Menderes grabeninin olduğu Aydın, Nazilli ve Sarayköy bölgelerinde düşük anomali değerleri gözlenmektedir. Şekil 3.12 incelendiğinde bölgedeki graben sistemlerinin uzanımları ve bölgeye ait jeolojik birimler görülmektedir.

Batı Türkiye Bouguer gravite anomali haritasında grabenler üzerinden ve Seferihisar jeotermal bölgesinden kesitler alınarak Yapay Sinir ağları ile değerlendirilmiş ve daha önce bölgede yapılan diğer çalışmalarla karşılaştırılmıştır. Bouguer gravite anomali haritasından alınan kesitler, aynı bölgelerde jeotermal ve enerji amaçlı açılmış kuyuların derinliklerini ve dağılımlarını gösteren harita Şekil 3.13 te görülmektedir.



Şekil 3.13 Batı Anadolu Bouguer gravite anomali haritası (kontur aralığı 5 mGal- MTA,1979).

3.1.2.3 Gediz Grabeni

Batı Türkiye’de K-G yönlü açılma tektoniğine bağlı olarak meydana gelen D-B uzanımlı Gediz grabeni bugüne kadar birçok araştırmacı tarafından çalışılmıştır. Grabenin güney kenarı boyunca uzanan düşük açılı normal fay karakterindeki ayrılma fayı bölgenin karakteristiğini en iyi yansıtan ve üzerinde en çok çalışılan faydır. Bugüne kadar çalışanların farklı isimlerle nitelendirdiği fay, (Karadut ayrılma fayı Emre, 1996; Çamköy ayrılma fayı Koçyiğit ve diğer., 1999; Gediz ayrılma fayı Lips ve diğer., 2001; Sözbilir, 2001 ve 2002) Menderes Masifi’ne ait temel kayalar ile Neojen yaşlı sedimanter örtü kayalarını birbirinden ayırmaktadır.

Batı Türkiye'nin en temel özelliği olan K-G açılma tektoniğine bağlı olarak gelişen ayrılma fayları ve bu fayların önünde çökelen kırıntılı kayalar, Gediz grabeni içinde beş farklı stratigrafik birimde bulunduğu belirtilmiştir. Bunlar, Gediz formasyonu, Alaşehir formasyonu, Kaletepe formasyonu, Çaltılık ve Bintepeleler formasyonudur (Çiftçi ve Bozkurt, 2009).

Gediz grabeninde bugüne kadar birçok araştırmacı tarafından tortul ve kabuk kalınlığını saptamaya yönelik çalışmalar yapılmıştır. Paton (1992) tarafından yapılan çalışmada graben üzerinde Salihli ve Alaşehir civarında alınan üç farklı gravite profilinin değerlendirilmesi sonucunda Salihli civarı için ortalama tortul kalınlığını 1,3 ve 1,4 km Alaşehir civarı için ise 1,3 km, birimler arası yoğunluk farkını $-0,65 \text{ gr/cm}^3$ olarak saptanmıştır. Gürer ve diğerleri (2002), biri grabenin ana eksenine paralel, diğeri dik olan iki ayrı profil boyunca aldıkları manyetotelürik (MT) verilerini değerlendirerek grabene ait tortul kalınlığının 950-3800 m arasında olduğunu belirtmişlerdir. Sarı ve Şalk (2006) bölgeye ait gravite verilerini değerlendirerek Gediz grabeni için tortul kalınlığının 1,5 -2 km arasında yoğunluk farkının ise $-0,5 \text{ gr/cm}^3$ olduğunu saptamışlardır. Bozkurt ve Sözbilir (2004) jeolojik çalışmalarla tortul kalınlığının Alaşehir grabeni için yaklaşık 1,3-1,5 km olduğunu belirtmişlerdir. Purvis ve Robertson (2005), Alaşehir civarından aldıkları jeolojik kesidi yorumlayarak derinliğin yaklaşık 1 km civarında olduğunu saptamışlardır. Yılmaz (2003) grabenin Alaşehir civarında grabeni yaklaşık dik konumda kesen ve grabenin ana eksenine paralel olarak alınan farklı 10 sismik yansıma profili verilerini değerlendirerek tortul kalınlığının 2-2,5 km olduğunu belirtmiştir.

Bölgede MTA ve Türkiye Petrolleri Anonim Ortaklığı (TPAO) tarafından jeotermal ve araştırma amaçlı birçok kuyu açılmıştır. Tablo 3.4' te bölgede açılan kuyulardan bazıları ve açıldığı alanlar verilmektedir. Alaşehir yakınlarında açılan kuyuların en derini 2,5 km, Salihli Kurşunlu jeotermal alanında ise açılan kuyuların maksimum derinliği 1189 m'dir .

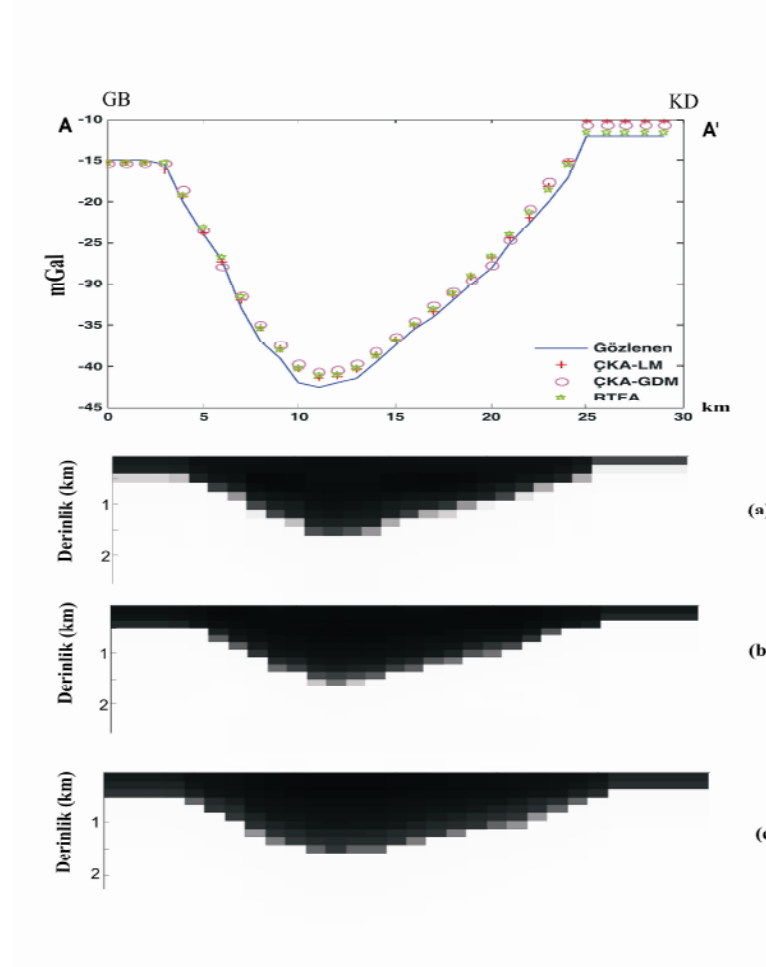
Tablo 3.4 Gediz grabeni ve çevresinde 1000 m'den derin olan sondajlar.

BÖLGEDE AÇILMIŞ SONDAJLAR		
Sondaj Yeri	Derinliği (m)	Açılma Nedeni
Salihli- Kurşunlu (SC-1)	1189	Jeotermal amaçlı
Alaşehir(BH-3)	2120	Araştırma
Alaşehir(BH-2)	2450	Araştırma
Alaşehir (BH-1)	2524	Araştırma

Grabene ait tortul kalınlığı ve yoğunluk farkının bulunması amacıyla Bouguer gravite anomali haritasından Salihli çevresinden alınan GB-KD uzanımlı A-A' ve B-B' kesitleri ile Alaşehir çevresinden alınan GB-KD uzanımlı C-C' kesidi ÇKA ve RTFA ile değerlendirilmiştir. Alınan kesitler Şekil 3.13 de görülmektedir. Elde edilen yoğunluk farkı değerlerinden olası yoğunluklar elde edilmiştir.

A-A' Profili

Eğitim seti kırk farklı modelden oluşmaktadır. Farklı katman sayıları, nöron sayıları, öğrenme ve momentum katsayılarına göre eğitilen ağ için en iyi sonucun elde edildiği 8 ve 5 nöronlu iki katmanlı ÇKA yapısı olmuştur. Öğrenme ve momentum katsayıları sırasıyla 0,5 ve 0,9 olarak alınmıştır. Veri seti [-1 1] aralığında normalize edilmiş ve hiperbolik tanjant aktivasyon fonksiyonu kullanılmıştır. ÇKA GDM için yoğunluk farkı ve derinlik değerleri $-0,57 \text{ gr/cm}^3$ ve 0,5-1,4 km olası yoğunluk değeri $2,33 \text{ gr/cm}^3$ olarak elde edilmiştir. ÇKA LM için yoğunluk farkı $-0,60 \text{ gr/cm}^3$ derinlik ise yaklaşık 0,3-1,5 km olası yoğunluk değeri ise $2,3 \text{ gr/cm}^3$ olarak saptanmıştır. RTFA için yoğunluk farkı $-0,60 \text{ gr/cm}^3$ derinlik ise 0,5-1,5 km olası yoğunluk değeri $2,3 \text{ gr/cm}^3$ olarak saptanmıştır. Elde edilen tüm modeller ve modellere karşılık hesaplanan anomaliler Şekil 3.14 de görülmektedir.

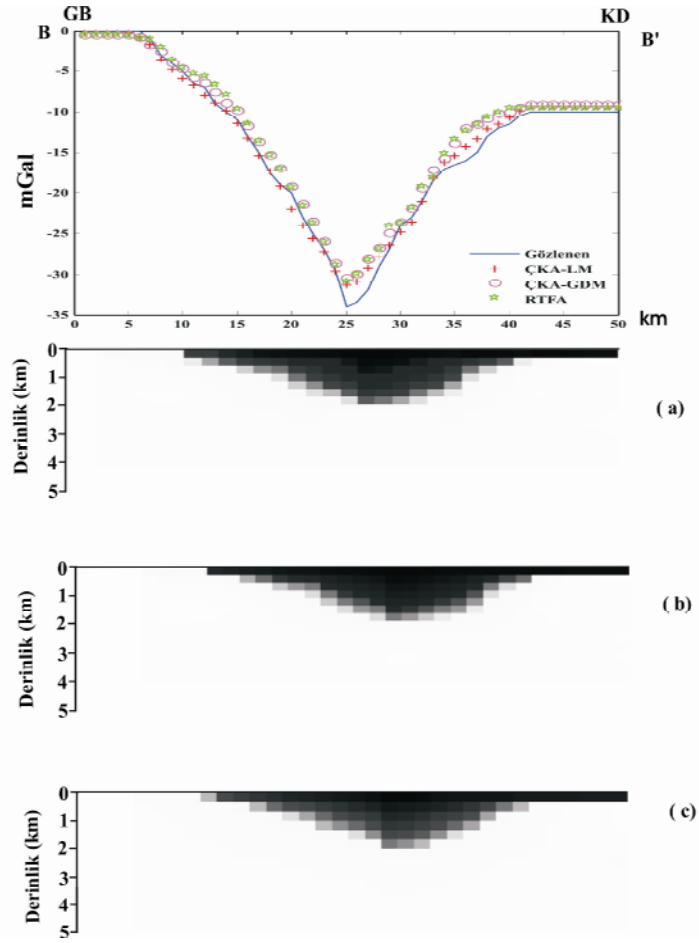


Şekil 3.14 (a) Gediz A-A' profil ÇKA LM sonucu.
 (b) Gediz A-A' profil ÇKA- GDM.
 (c) Gediz A-A' profilinin RTFA sonucu.

B-B' Profili

Eğitim setinin otuzsekiz farklı modelden oluştuğu gizli katmanlarında 5 ve 3 nöron bulunan ÇKA en iyi sonucun elde edildiği ağ yapısıdır. Öğrenme ve momentum katsayıları sırasıyla 0,4 ve 0,9 alınmıştır. Aktivasyon fonksiyonu olarak hiperbolik tanjant kullanılmış ve veriler [-1 1] aralığında normalize edilmiştir. ÇKA LM ile elde edilen derinlik ve yoğunluk farkı değerleri sırasıyla yaklaşık 0,3-2 km ve -0,60 gr/cm^3 olası yoğunluk değeri ise 2,3 gr/cm^3 olarak saptanmıştır. ÇKA GDM için derinlik ve yoğunluk farkı değerleri yaklaşık 0,3-1,8 km ve -0,61 gr/cm^3 olası yoğunluk değerinin ise 2,29 gr/cm^3 olduğu görülmüştür. RTFA için saptanan derinlik

ve yoğunluk farkı değerleri ise yaklaşık 0,3-2 km ve $-0,65 \text{ gr/cm}^3$ olası yoğunluk değeri ise $2,25 \text{ gr/cm}^3$ 'tür. Elde edilen tüm modeller Şekil 3.15 de görülmektedir.



Şekil 3.15 (a) Gediz B-B' profilinin ÇKA LM sonucu.

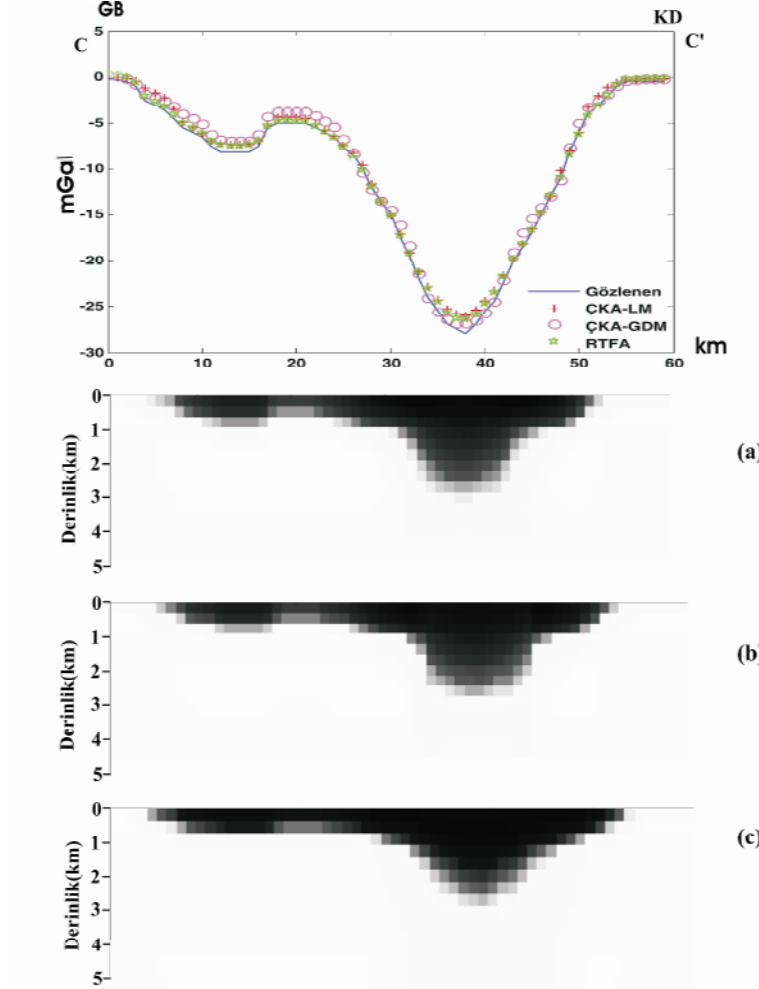
(b) Gediz B-B' profilinin ÇKA GDM sonucu.

(c) Gediz B-B' profilinin RTFA sonucu.

C-C' Profili

Eğitim seti birbirinden farklı kırk modelden oluşmaktadır. En iyi sonucun elde edildiği gizli katmanlarında 8 ve 5 nöron bulunan iki katmanlı ÇKA için öğrenme ve momentum katsayıları sırasıyla 0,4 ve 0,7' dir. Aktivasyon fonksiyonu olarak hiperbolik tanjant kullanılmıştır. Veriler $[-1 \ 1]$ aralığında normalize edilmiştir. ÇKA LM için derinlik ve yoğunluk farkı yaklaşık 0,8-2,5 km ve $-0,55 \text{ gr/cm}^3$ olası yoğunluk değeri ise $2,35 \text{ gr/cm}^3$ olarak saptanmıştır. ÇKA GDM için ise derinlik ile yoğunluk farkı değerleri yaklaşık 0,8-2,4 km ve $-0,55 \text{ gr/cm}^3$ olası yoğunluk değeri

ise $2,35 \text{ gr/cm}^3$ olarak bulunmuştur. RTFA sonuçları ise derinlik için yaklaşık 0,8-2,5 km, yoğunluk farkı için ise $-0,57 \text{ gr/cm}^3$ olası yoğunluk değeri ise $2,33 \text{ gr/cm}^3$ 'tür. Elde edilen tüm modeller Şekil 3.16 da görülmektedir.

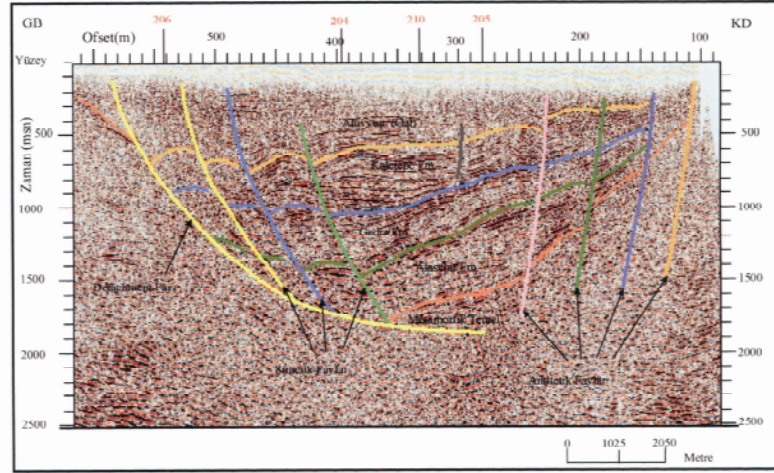


Şekil 3.16 (a) Gediz C-C' profilinin ÇKA LM sonucu.

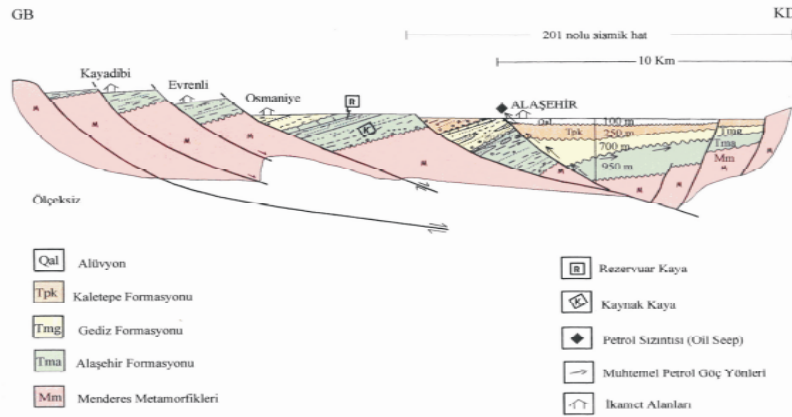
(b) Gediz C-C' profilinin ÇKA GDM sonucu.

(c) Gediz C-C' profilinin RTFA sonucu.

Yılmaz (2003) çalışmasında Alaşehir grabeninin petrol potansiyelini araştırmak amacıyla toplanan sismik yansıma verilerini yorumlamış ve graben için yaklaşık derinliğin 2 ile 2,5 km olduğunu belirtmiştir. C-C' gravite profili ile yaklaşık aynı doğrultuda alınan sismik hattın migrasyon kesidi Şekil 3.17 de görülmektedir.

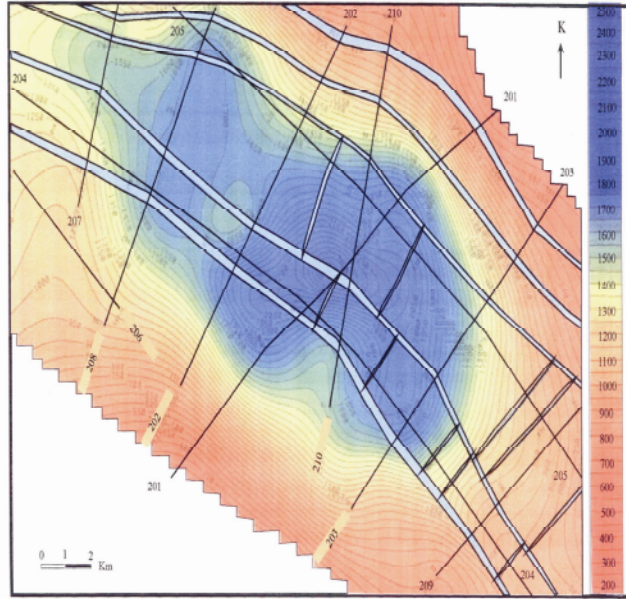


Şekil 3.17 Yaklaşık GB- KD yönlü hattın sismik migrasyon kesiti (Yılmaz, 2003).



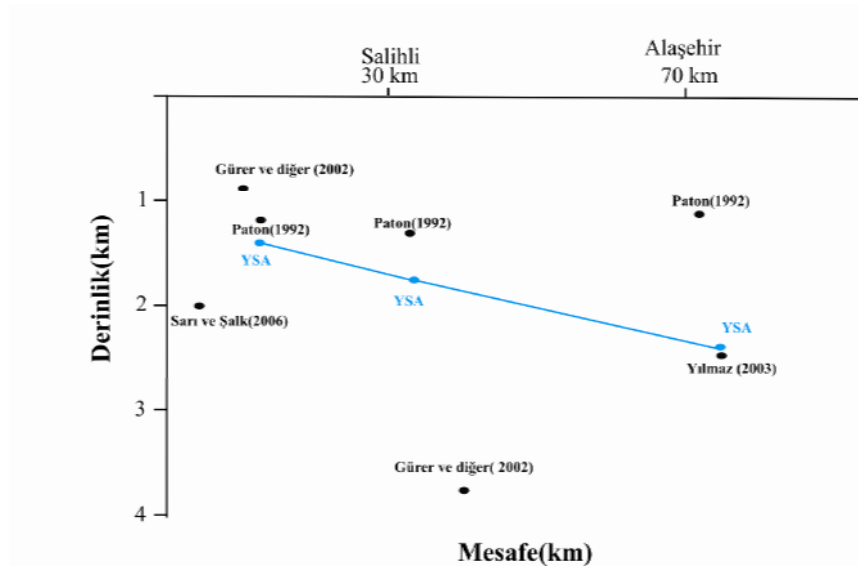
Şekil 3.18 Yaklaşık GB- KD uzanımlı sismik hattın yardımıyla oluşturulan Alaşehir grabeni jeotektonik kesidi (Yılmaz, 2003).

Yılmaz (2003) tarafından yorumlanmış yaklaşık K-G doğrultulu sismik hattın jeotektonik kesidi Şekil 3.18 de görülmektedir. Kesitteki derinlik değerleri sismik kesit yardımıyla bulunmuş yaklaşık değerlerdir. Sismik kesitleri kullanarak olası temel derinliğini çıkarmıştır. Şekil 3.19 da görülen derinlik haritası incelendiğinde metamorfik temele kadar dört çökel istifin toplam kalınlığının 2500 m olduğu görülmektedir (Yılmaz, 2003).



Şekil 3.19 Olası temel girişi (menderes metamorfikleri) derinlik haritası (Yılmaz, 2003).

Alaşehir grabeni içinde TPAO tarafından yaklaşık K-G ve D-B doğrultulu iki profil gravite ve manyetik ölçümler alınmıştır. Gravite ve manyetik verilerinin değerlendirilmesi sonucunda metamorfik temel derinliği yaklaşık 2 km olarak saptanmıştır (Yılmaz, 2003).



Şekil 3.20 Gediz grabeni için kalınlıklar.

Graben üzerinde bugüne kadar yapılan çalışmaların sonucunda elde edilen derinlikler ve bu tezin kapsamında bulunan YSA sonuçları Şekil 3.20 de özetlenmeye çalışılmıştır. Yapılan son çalışmalar ve YSA değerleri grabende tortul kalınlığının batından doğuya doğru arttığını göstermektedir.

3.1.2.4 Büyük Menderes Grabeni

Batı Türkiye’ de K-G açılma tektoniğine bağlı olarak oluşan D-B uzanımlı ikinci temel grabendir. Büyük Menderesin kuzey kenarı boyunca düşük açılı normal faylar, K-G uzanımlı oblique normal faylar ve yaklaşık D-B uzanımlı yüksek açılı normal faylar olmak üzere üç farklı fay oluşumu gözlenmektedir. Grabenin kuzey kenarı düşük açılı normal fay olan Büyük Menderes ayrılma fayı menderes masifine ait metamorfik kayalar ile grabenin sediment dolgusunu birbirinden ayırmaktadır (Bozkurt, 2000; Emre ve Sözbilir, 1995).

Bugüne kadar Büyük Menderes grabeninin sediment kalınlığının saptanması yönünde çeşitli çalışmalar yapılmıştır. Paton (1992) yaptığı çalışmada graben için tortul kalınlığının 1,5 km yoğunluk farkının ise $-0,65 \text{ g/cm}^3$ olduğunu belirtmiştir. Aynı bölge için Sarı ve Şalk (2006) gravite verilerinin 3 boyutlu ve 2 boyutlu analizini yaparak tortul kalınlığının 1,5 km den fazla olabileceğini özellikle Sarayköy- Kızıldere bölgesinde 2 km den daha kalın olduğunu ve Büyük Menderes grabeni için maksimum tortul kalınlığının 2,5 ile 3,5 km arasında değiştiğini belirtmişlerdir. Işık ve Şenel (2009) ise graben için maksimum kalınlığın 3,9 km olduğunu belirtmişlerdir.

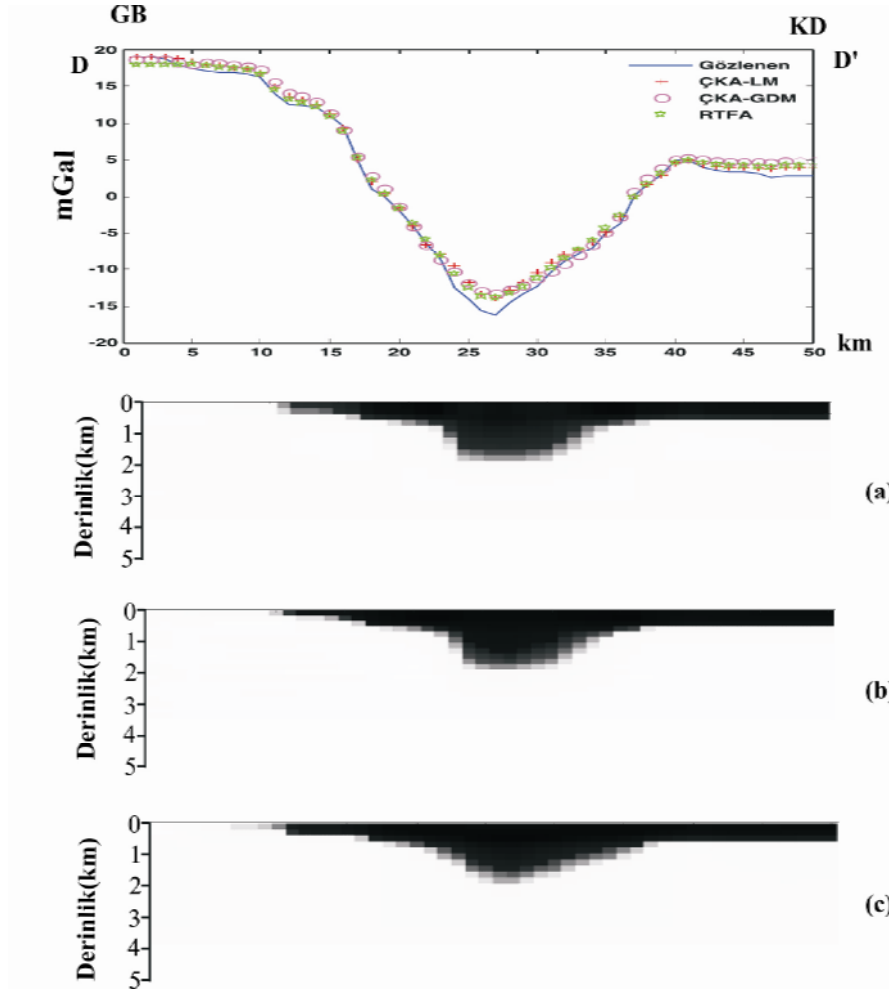
Cohen ve arkadaşları (1995) Aydın civarı için tortul kalınlığını 1,5 km olarak bulmuşlardır. Işık 1997 yılında yaptığı çalışmada Aydın ve Sultanhisar arasındaki bölge için kalınlığın 2-2,2 km, Sultanhisar ve Nazilli arası için 2,2-2,3 km olduğunu belirtmektedir. Şenel (1997) Sultanhisar ve Nazilli arasındaki bölgenin sediment kalınlığını 2,5 km olarak saptamıştır. Bölgede açılan sondajlar ve derinlikleri Tablo 3.5 da verilmektedir.

Tablo 3.5 Büyük Menderes grabeninde 900 m' den derin sondajlar.

BÖLGEDE AÇILMIŞ SONDAJLAR		
Sondaj Yeri	Derinliği (m)	Açılma Nedeni
Germencik -Ömerbeyli-Bozköy(ÖB-2)	975,5	Jeotermal amaçlı
Germencik -Ömerbeyli-Bozköy(ÖB-1)	1000	Jeotermal amaçlı
Germencik -Ömerbeyli-Bozköy(ÖB-6)	1100	Jeotermal amaçlı
Germencik -Ömerbeyli-Bozköy(ÖB-3)	1196,7	Jeotermal amaçlı
Germencik -Ömerbeyli-Bozköy(ÖB-9)	1464,7	Jeotermal amaçlı
Germencik -Ömerbeyli-Bozköy(ÖB-7)	2398	Jeotermal amaçlı
Sultanhisar-Salavatlı(AS-1)	1510	Jeotermal amaçlı
Kızıldere (KD-21)	898	Jeotermal amaçlı
Kızıldere(KD-9)	1241	Jeotermal amaçlı

D-D' Profili

Büyük Menderes grabeni Aydın yakınlarından alınan GB- KD doğrultulu D-D' gravite kesidi gizli katmanlarında 5 ve 3 nöron bulunan ÇKA ve RTFA ile değerlendirilmiştir. Eğitim seti birbirinden farklı otuzbeş modelden oluşmaktadır. Çeşitli denemeler sonucunda öğrenme katsayısı 0,5 ve momentum katsayısı 0,9 olarak alınmıştır. ÇKA LM için derinlik, yoğunluk farkı değerleri sırasıyla 0,5-1,7 km ve $-0,5 \text{ gr/cm}^3$, olası yoğunluk değeri ise $2,4 \text{ gr/cm}^3$ 'tür. ÇKA GDM için ise derinlik 0,5-1,8 km ve yoğunluk farkı $-0,55 \text{ gr/cm}^3$, olası yoğunluk değeri $2,35 \text{ gr/cm}^3$ olarak elde edilmiştir. RTFA için derinlik değeri 0,5-1,8 km, yoğunluk farkı ise $-0,55 \text{ gr/cm}^3$ ve olası yoğunluk değeri ise $2,35 \text{ gr/cm}^3$ olarak saptanmıştır. Tüm modeller ve sonuçlar Şekil 3.21 de görülmektedir.



Şekil 3.21 (a) Büyük Menderes D-D' profilinin ÇKA LM sonucu.

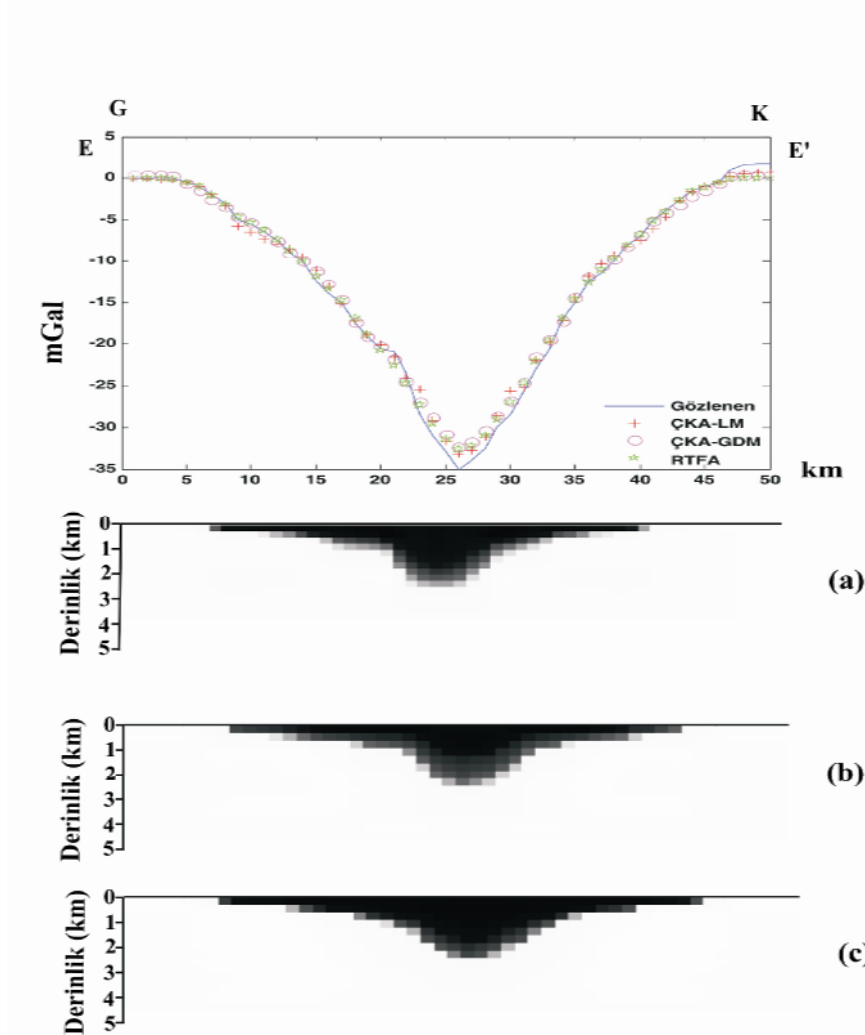
(b) Büyük Menderes D-D' profilinin ÇKA GDM sonucu.

(c) Büyük Menderes D-D' profilinin RTFA sonucu.

E-E' Profili

Büyük Menderes grabeni üzerinde Nazilli yakınlarından alınan G-K uzanımlı E-E' gravite profili ÇKA ve RTFA ile değerlendirilmiştir. Ağrı eğitmek için birbirinden farklı otuzyedü model oluşturulmuştur. Çeşitli denemeler sonucunda en uygun ÇKA yapısının birinci katmanda 8 ikinci katmanda 5 nöron bulunduran ağ olduğu görülmüştür. Öğrenme katsayısı 0,5 ve momentum katsayısı 0,9 seçilmiştir. ÇKA LM için derinlik ve yoğunluk değerleri sırasıyla yaklaşık 2,1 km ve $-0,62 \text{ gr/cm}^3$,

olası yoğunluk değeri ise $2,28 \text{ gr/cm}^3$ olarak saptanmıştır. ÇKA GDM için ise derinlik değeri yaklaşık $2,2 \text{ km}$ ve yoğunluk farkı ise $-0,60 \text{ gr/cm}^3$ olası yoğunluk değeri ise $2,3 \text{ gr/cm}^3$ olarak elde edilmiştir. Aynı profil için RTFA sonuçları ise derinlik için $2,3 \text{ km}$ ve yoğunluk farkı için $-0,57 \text{ gr/cm}^3$ olası yoğunluk değeri ise $2,33 \text{ gr/cm}^3$ olarak bulunmuştur. Elde edilen sonuçlar ve modeller Şekil 3.22 de görülmektedir.




Şekil 3.22 (a) Büyük Menderes E-E' profili ÇKA LM sonucu.

(b) Büyük Menderes E-E' profili ÇKA GDM sonucu.

(c) Büyük Menderes E-E' profil RTFA sonucu.

F-F' Profili

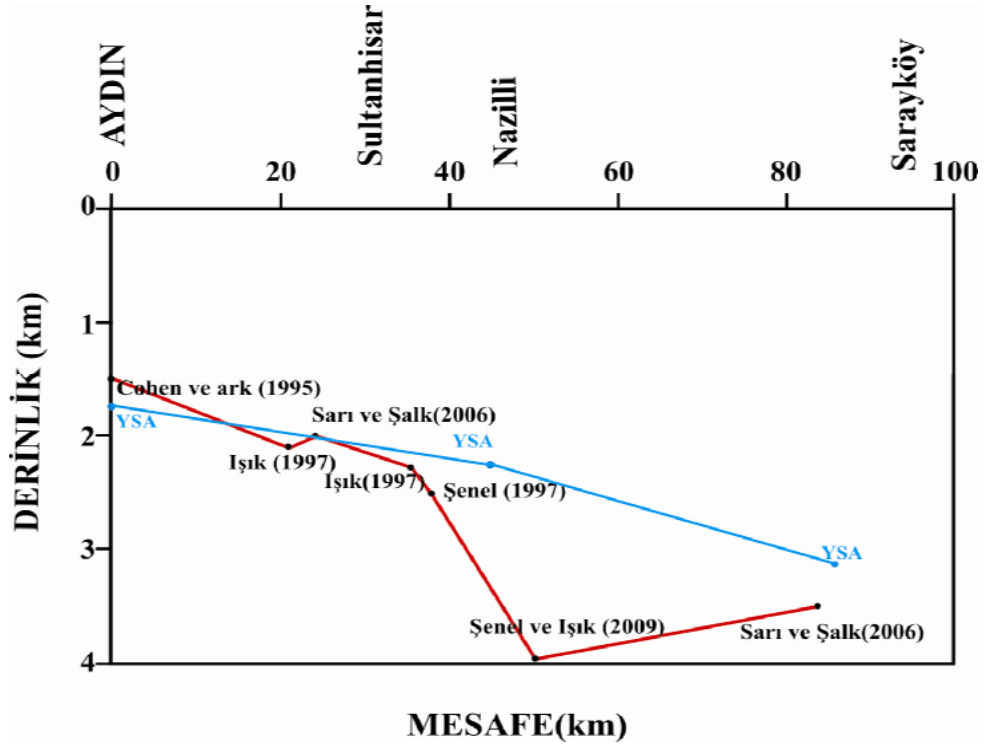
Eđitim seti birbirinden farklı otuzyedı model ve modellere karřılık gelen gravite anomalilerinden oluřmaktadır. Sarayky yakınlarından alınan GB-KD uzanımlı F-F' gravite profili katmanlarında 5 ve 3 nron bulunan KA ve RTFA ile deđerlendirilmiřtir. eřitli denemeler sonucunda đrenme katsayısı 0,5 ve momentum katsayısı 0,9 olarak alınmıřtır. KA LM iin elde edilen derinlik, yođunluk farkı deđerleri sırasıyla 1-3,2 km ve $-0,5 \text{ gr/cm}^3$ olası yođunluk deđerı ise $2,4 \text{ gr/cm}^3$ tr. KA GDM iin ise derinlik 1-3,2 km ve yođunluk farkı $-0,51 \text{ gr/cm}^3$ olası yođunluk ise $2,39 \text{ gr/cm}^3$ olarak elde edilmiřtir. RTFA iin derinlik deđerı 1-3,2 km, yođunluk farkı ise $-0,55 \text{ gr/cm}^3$ olası yođunluk ise $2,35 \text{ gr/cm}^3$ olarak saptanmıřtır.



řekil 3.23 (a) Byk Menderes F-F' profili KA LM sonucu.

(b) Byk Menderes F-F' profili KA GDM sonucu.

(c) Byk Menderes F-F' profili RTFA sonucu.



Şekil 3.24 Büyük Menderes grabeni derinlikler (Şenel ve Işık, 2009 dan derlenmiştir).

Bugüne kadar Büyük Menderes grabeni üzerinde yapılan çalışmalardan elde edilen sonuçlar ve YSA ile elde edilen derinlik değerleri Şekil 3.24 te verilmektedir. Elde edilen sonuçlar grabenin kalınlığının batıdan doğuya doğru arttığını göstermektedir.

3.1.2.5 Seferihisar Jeotermal Bölgesi

Seferihisar, İzmir'in yaklaşık 40 km güneybatısında yer almaktadır. Bu bölgede aktif graben- horst tektoniği hakimdir. Temel tektonik özellik kuzeydoğu-güneybatı uzanımlı faylar ve kırıklardır. Bölgenin orta kesiminde KD-GB uzanımlı Çubuklu Dağ grabeni vardır.

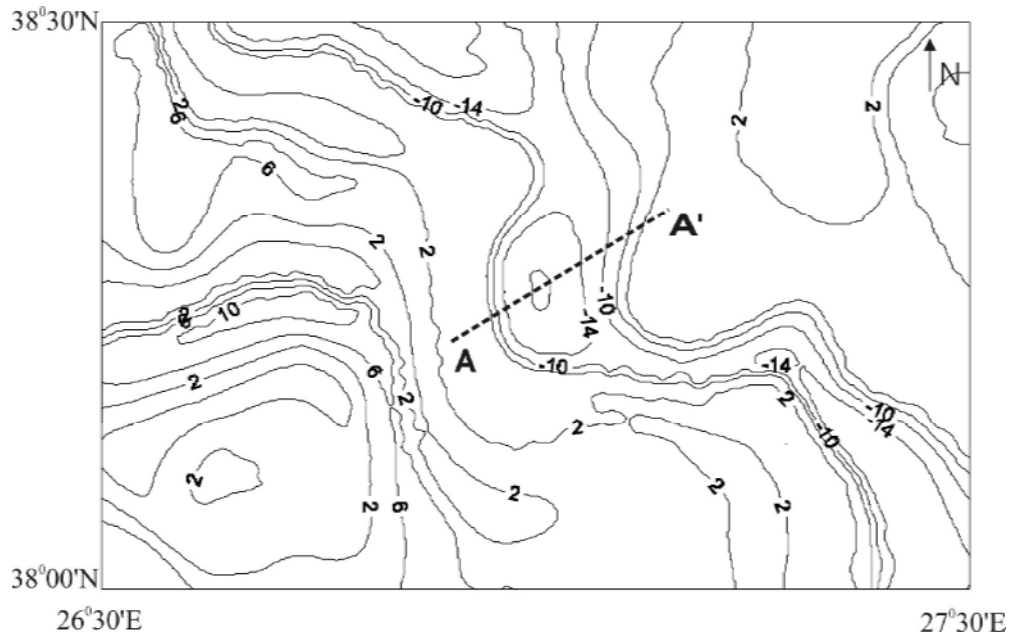
Aynı bölgede daha önce yaptıkları çalışmada Drahor ve arkadaşları (1999) gravite anomali haritası verilerine üç boyutlu ters çözüm işlemiyle alanın metamorfik taban derinliğini 1,6 km olarak saptamışlardır. Yoğunluk farkını ise $-0,3 \text{ gr/cm}^3$ olarak belirtmişlerdir. Rezidüel Bouguer anomali haritası üzerinden aldıkları kesit verilerine göre $-0,3 \text{ gr/cm}^3$ yoğunluk farkı için uygulanan iki boyutlu ters çözüm

işlemi sonucunda ise metamorfik tabanın derinliğini 1,7 km olarak saptamışlardır. Bouguer gravite verileri için yaptıkları değerlendirmeler sonucunda; bölgenin tortul kalınlığının 1,5-1,7 km arasında olduğunu belirtmişlerdir.


Tablo 3.6 Seferihisar jeotermal bölgesinde derinliği 1200 m'den fazla olan sondajlar.

BÖLGEDE AÇILMIŞ SONDAJLAR		
Sondaj Yeri	Derinliği (m)	Açılma Nedeni
Seferihisar(SH-2)	1232	Jeotermal amaçlı
Cumalı(CM-1)	1417	Jeotermal amaçlı
Tuzla(TZ-1)	2009	Jeotermal amaçlı

Bölgede MTA tarafından açılan sondajlar incelenirse en derin sondajın Tuzla bölgesinde 2009 m derinliğinde olduğu görülmektedir. Tablo 3.6 da bölgede açılan sondajlar ve derinlikleri verilmektedir.



anomalileri ağı eğitmek için kullanılmıştır. Hesaplanan anomaliler girdi, oluşturulan modeller çıktı olacak şekilde ağı eğitilmiştir. Bouguer gravite anomali haritasından alınan A-A' kesiti ise test amacıyla kullanılmıştır. Gizli katmanlarında 8 ve 5 nöron bulunan ÇKA kullanılmıştır. Öğrenme ve momentum katsayıları sırasıyla 0,5 ve 0,9 olarak alınmıştır. ÇKA LM için elde edilen derinlik ve yoğunluk farkı değerleri sırasıyla 1,5 km ve $-0,37 \text{ gr/cm}^3$ yoğunluk değeri yaklaşık $2,43 \text{ gr/cm}^3$ tür. ÇKA GDM ile derinlik 1,6 km, yoğunluk farkı ise $-0,37 \text{ gr/cm}^3$ olası yoğunluk değeri ise $2,43 \text{ gr/cm}^3$ olarak saptanmıştır. Aynı veri seti RTFA ile de eğitilmiştir. Elde edilen derinlik değeri 1,7 km ve yoğunluk farkı ise $-0,35 \text{ gr/cm}^3$ olası yoğunluk değeri ise $2,45 \text{ gr/cm}^3$ olarak elde edilmiştir. Tüm YSA modelleri her bir ağı türü için Şekil 3.26 da verilmektedir.

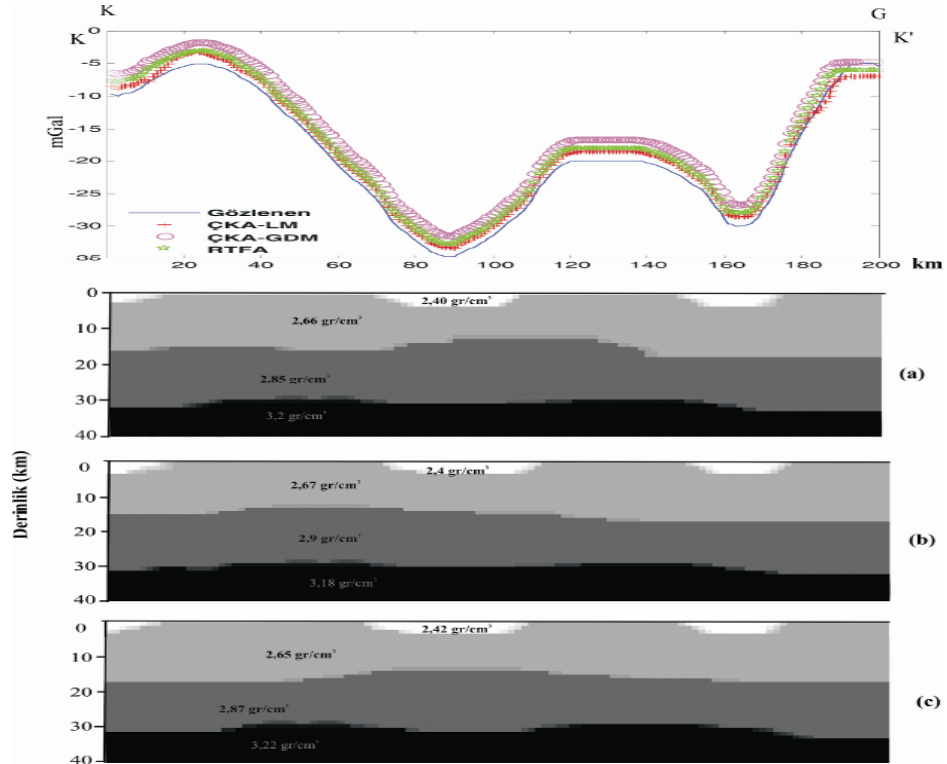


Şekil 3.26 (a) Seferihisar A-A' profili ÇKA LM sonucu.
 (b) Seferihisar A-A' profili ÇKA GDM sonucu.
 (c) Seferihisar A-A' profili RTFA sonucu.

3.1.2.6 Batı Anadolu'nun Kabuk Kalınlığının Saptanması

Batı Anadolu'nun kabuk kalınlığını saptamaya yönelik birçok çalışma yapılmıştır. Mindevalli ve Mitchel (1989) Rayleigh ve Love dalgalarının grup hızlarını kullanarak bölge için ortalama kabuk kalınlığının yaklaşık 40 km olduğunu belirtmişlerdir. Benzer şekilde Ezen (1991), Rayleigh dalga dispersiyonunu kullanarak kabuk kalınlığını yaklaşık 30 – 32 km olarak saptamıştır. Göktürkler ve diğerleri (2003) yaklaşık 30 km olduğunu belirtmişlerdir. Akçığ (1988) çalışmasında Ege Denizinde ortalama 30 km olan kabuk kalınlığının Batı Anadolu'da 35-40 km'ye ulaştığını belirtmiştir.

Bu çalışmada Bouguer gravite anomali haritası üzerinden K-G uzanımlı bir profil alınarak kabuk kalınlığı saptanmıştır. Eğitim setinde birbirinde farklı derinlik, yoğunluk farkı ve geometriye sahip toplam ellibeş model kullanılmıştır. Katmanlarında 30 ve 20 nöron bulunduran öğrenme katsayısı 0,4 ve momentum katsayısı 0,9 ÇKA yapısı kullanılmıştır. ÇKA ve RTFA kullanılarak kabuk kalınlığı yaklaşık 32 km olarak saptanmıştır.



Şekil 3.27 (a) K-K' profilinin ÇKA LM sonucu.

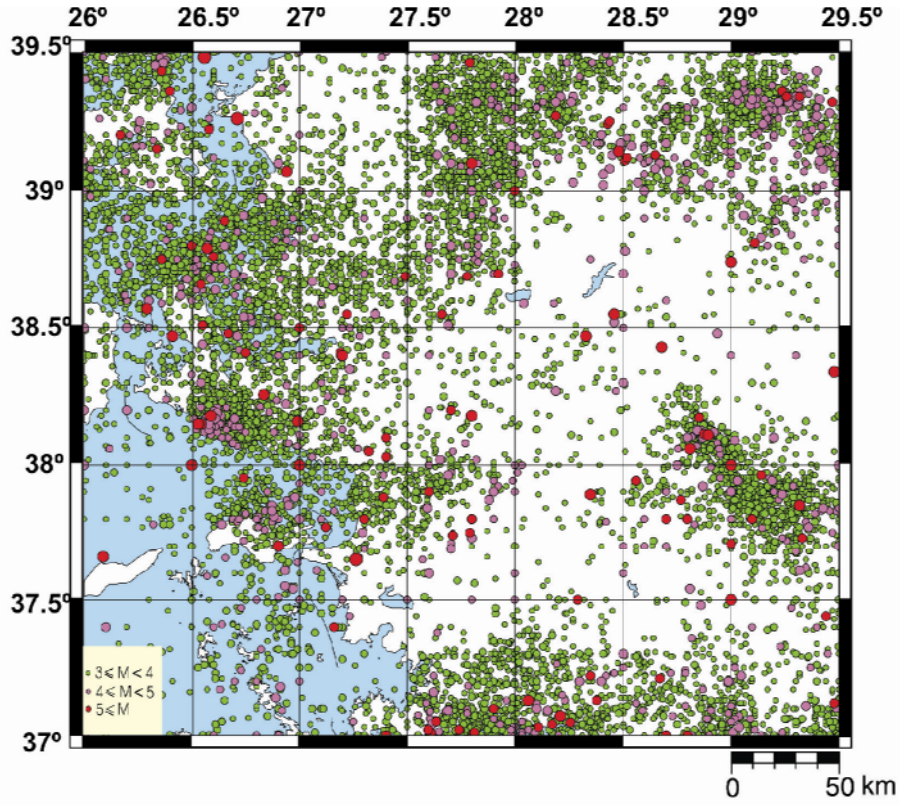
(b) K-K' profilinin ÇKA GDM sonucu.

(c) K-K' profilinin RTFA sonucu.

3.1.2.7 Batı Anadolu Deprem Frekanslarının Yapay Sinir Ağları ile Değerlendirilmesi


Dünya üzerindeki jeolojik ve tektonik konumu nedeniyle Türkiye, depremlerin yoğun olduğu ülkelerdendir. Özellikle Batı Anadolu'daki açılma tektoniğinin etkisiyle oluşan graben sistemleri depremsellik açısından oldukça aktiftir. Türkiye Deprem Bölgesi arasında Batı Anadolu birinci derece deprem kuşağının içinde yer almaktadır. 1900'lü yılların başından itibaren "Alemlsel Dönem" olarak adlandırılan ve günümüze kadar uzanan dönem içinde Batı Anadolu' da çok sayıda deprem meydana gelmiştir. Bu depremlerin bazıları bölgede can kaybı ve maddi hasarlara neden olmuştur. Son yüzyılda meydana gelen depremler içerisinde en büyük deprem 31 Mart 1928 tarihli 6,5 büyüklüğündeki Torbalı depremidir. Bu deprem çok geniş bir alanda etki yapmış, 2000'den fazla ev yıkılmış yada hasar görmüştür. İzmir güneyinde meydana gelmiş olan 6 Kasım 1992 depreminin büyüklüğü ise 6,0'dır. 2003 yılında meydana gelmiş olan 5,7 büyüklüğündeki Urla depremi ise Seferihisar'da az hasara yol açmıştır. Bölgede yakın zamanda meydana gelen büyüklükleri 5,7- 5,9 ve 5,6 olan Sığacık 2005 depremleri İzmir ve yakın çevresini kuvvetlice etkilemiş, depremlerde can kaybı olmamış ancak bazı binalarda çatlamlar şeklinde hasarların geliştiği gözlenmiştir.

Bu çalışmada Batı Anadolu da 37^0 - 39.30^0 kuzey enlemleri ile 26^0 – 29.30^0 doğu boylamları arasında kalan bölgede 1975 ve 2009 yılları arasında meydana gelmiş magnitudü 3 ve 3 ten büyük depremler seçilmiştir. Belirtilen yıllarda bölgede 3 ve 3 ten büyük 10333 deprem meydana geldiği gözlenmiştir. Çalışma alanı ve meydana gelen depremler Şekil 3.28 de gösterilmektedir. Bölgede oluşan bu depremlerin aylık frekansları hesaplanarak yapay sinir ağları ile değerlendirilmiştir. Her ay meydana gelen deprem sayıları toplanarak deprem frekans veri seti oluşturulmuştur. Çalışılan dönemde ve alanda $2009-1975 = 34$ yıl ve her yıl 12 ay olmak üzere $34 \times 12 = 408$ frekans değeri elde edilmiştir. Frekans değerleri Şekil 3.29 da gösterilmektedir.



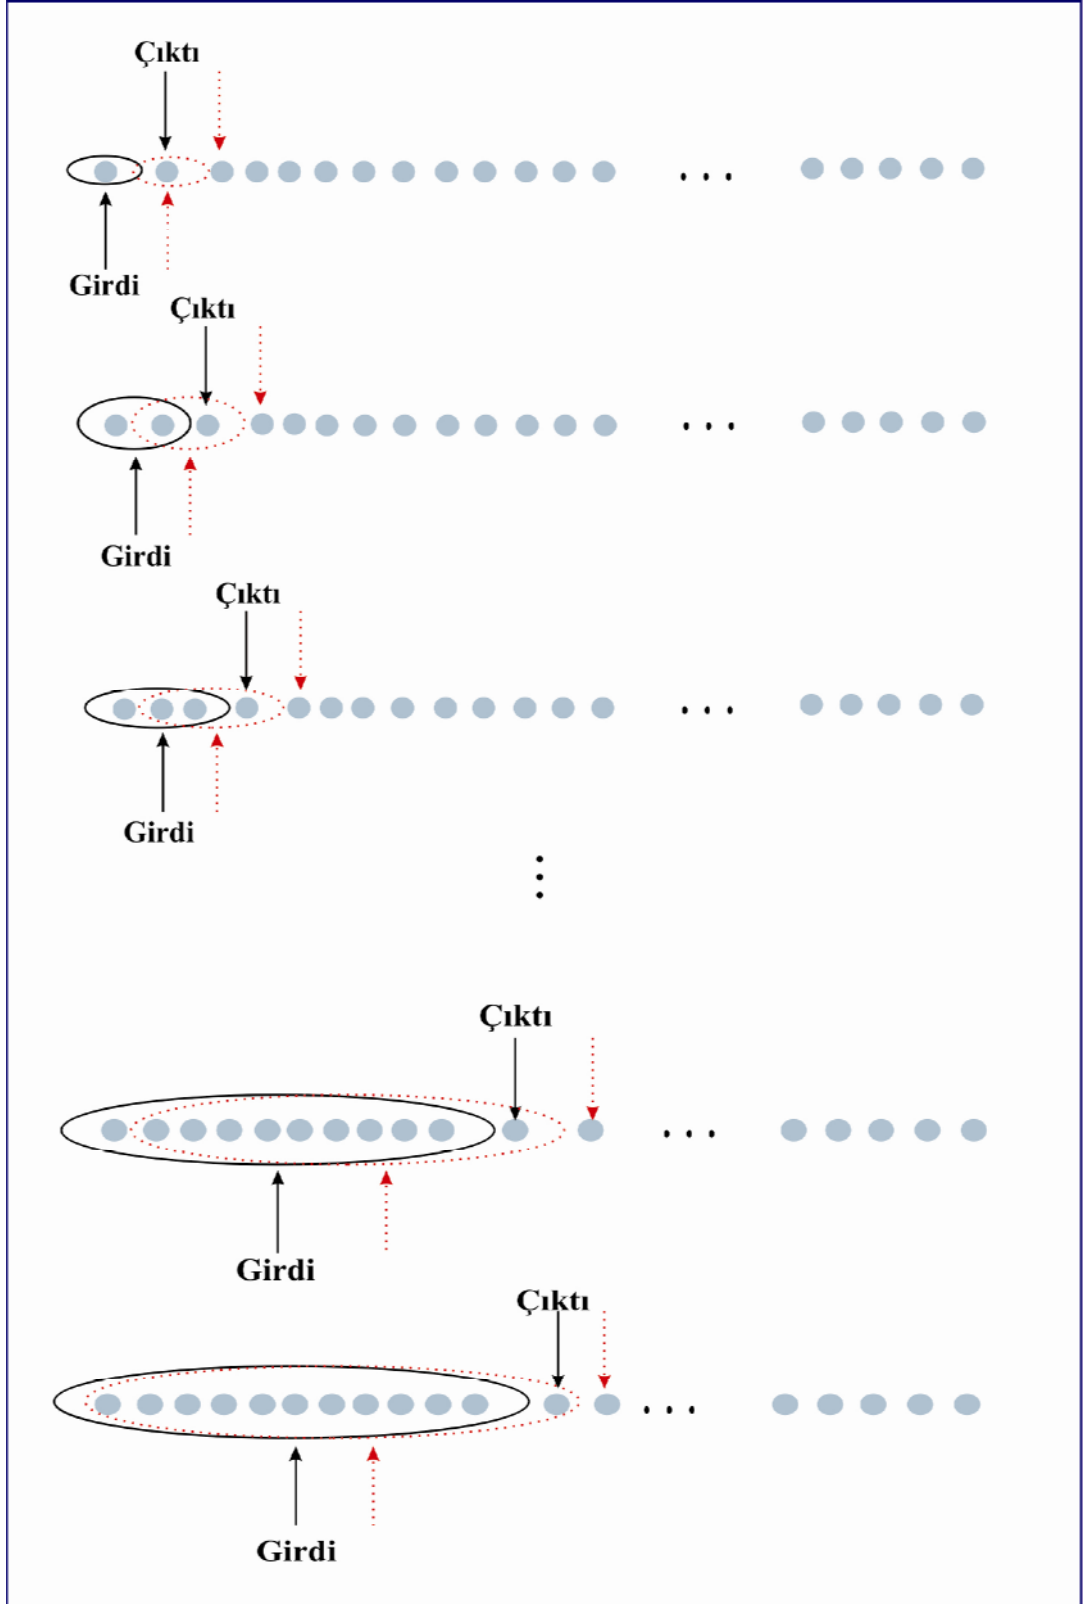
Şekil 3.28 Çalışma alanı ve 1975-2009 yılları arasında meydana gelen depremler.

Tüm veri setindeki 408 ayın frekans değeri içinden eşit aralıklarla % 15 oranında 58 aya ait frekans değeri test amaçlı olarak çıkarılmıştır. Eğitim ve test setindeki frekans değerleri yapay sınır ağlarına 1, 2, 3, 4, 5, 6, 7, 8, 9, 10 ve 11 girdili setler olacak şekilde düzenlenmiştir. Çalışma alanına ait deprem frekans değerleri Şekil 3.29 da görülmektedir. 2005 yılı ekim ayında İzmir yakınlarında yaşanan büyük depremler nedeniyle oluşan öncü ve artçı depremler o aya ait frekans değerinin yüksek olarak saptanmasına neden olmuştur. Eğitim seti 350 ayın frekans değerlerinden oluşmaktadır. Tüm veri seti ise test amacıyla kullanılmıştır.



Şekil 3.29 1975-2009 yılları arasında Batı Anadolu da meydana gelen $M \geq 3$ depremleri için aylık frekanslar.

Frekans değerleri 11 farklı girdi seti ile eğitilerek her durum için test edilmiştir. Her durumda girdi değerlerinden bir sonraki frekans değeri ağıın çıktısı olacak şekilde eğitim ve test setleri düzenlenmiştir. Her farklı girdi için yapılan düzenleme Şekil 3.30 da gösterilmektedir. Oluşturulan setler ÇKA ve RTFA ile değerlendirilmiştir. Her iki ağ türü için elde edilen sonuçlar ile gözlenen deprem frekansları arasındaki korelasyon katsayıları hesaplanmıştır. Elde edilen korelasyon katsayıları Tablo 3.7 ve Şekil 3.31 de verilmektedir.




Şekil 3.30 Girdilerin ve çıktılarının ağa verilmiş durumları.

Tablo 3.7 ÇKA ve RTFA için elde edilen korelasyon katsayıları.

KORELASYON KATSAYILARI											
	1 Girdili	2 Girdili	3 Girdili	4 Girdili	5 Girdili	6 Girdili	7 Girdili	8 Girdili	9 Girdili	10 Girdili	11 Girdili
ÇKA	0,18	0,29	0,35	0,38	0,34	0,29	0,24	0,20	0,16	0,12	0,08
RTFA	0,30	0,93	0,91	0,87	0,81	0,66	0,59	-	-	-	-

Farklı uzunluklaki girdi setleri için elde edilen korelasyon katsayıları incelenecek olursa her iki ağ türü için de 2, 3 ve 4 girdili setlerde tahmin edilen ile gerçek frekans değerleri arasındaki korelasyon katsayısının yüksek olduğu, 5 girdili setden sonra korelasyon katsayısının azaldığı görülmektedir. RTFA için 8 girdili ve sonrasındaki çalışmalar için korelasyon katsayıları çok düşük olduğundan Tabloda gösterilmemiştir.




Şekil 3.31 ÇKA ve RTFA için korelasyon katsayıları.

Elde edilen frekans değerlerinin ortalama karekök hataları (Root Mean Square Error) hesaplanarak Tablo 3.8 de verilmiştir. Korelasyon katsayıları ile Ortalama Karekök Hata (OKH) birlikte incelendiğinde korelasyon katsayısının yüksek olduğu frekans değerleri için hesaplanan OKH değerleri düşük çıkmıştır. En yüksek korelasyon değeri olan RTFA 2 girdili set için en düşük OKH hesaplanmıştır.

Tablo 3.8 Frekanslar için elde edilen OKH değerleri.


Ortalama Karekök Hata değerleri					
	1 Girdili	2 Girdili	3 Girdili	4 Girdili	5 Girdili
ÇKA	57,32738	50,80562	42,76542	39,59562	43,63083
RTFA	38,82377	13,86354	15,6414	19,60015	25,11318

Her iki ağ türü için elde edilen frekansların hataları Şekil 3.32 de verilmektedir. OKH değerlerinden de anlaşılacağı üzere RTFA ile elde edilen frekans değerleri gerçek değerlerle daha uyumludur. Korelasyon katsayısı ÇKA sonuçlarına göre daha yüksek ve OKH değerleri ÇKA sonuçlarından daha düşüktür.




Şekil 3.32 Hesaplanan OKH değerleri.

Her iki ağ türü içinde sonuçlardan görüldüğü gibi RTFA ile gerçek frekans değerlerine daha uyumlu sonuçlar elde edilmiştir. Şekil 3.31 de ÇKA ve RTFA korelasyon katsayısı dağılımı görülmektedir. Tablo 3.7 ve Şekil 3.31 incelendiğinde 5 girdili setten sonra elde edilen sonuçların korelasyon katsayısının azaldığı ve elde edilen frekans değerlerinin gerçek frekans değerlerinden uzaklaştığı gözlenmektedir.



Şekil 3.33 İki girdili RTFA için elde edilen sonuç.

İki girdili set için elde edilen RTFA sonucu Şekil 3.33 de verilmektedir. Korelasyon değerinden de anlaşılacağı üzere gerçek frekans değerleri ile en iyi uyumun yakalandığı durumdur.



Şekil 3.34 Dört girdili ÇKA için elde edilen sonuç.

Dört girdili set için 15 nöronlu tek katmandan oluşan öğrenme katsayısı 0,2 olan ÇKA yapısı kullanılmıştır. Eğitim seti için ortalama karesel hata 0,0001 olarak alınmıştır. Elde edilen frekans değerleri Şekil 3.34 de görülmektedir. ÇKA için en iyi sonucun elde edildiği durumdur.

Deprem aylık frekans verilerinin gömülü boyutunu (embedding dimension) hesaplamak amacıyla çalışmalar yapılmıştır. Ancak gerek veri sayısının azlığı ve gerekse veri setinin gürültülü bir yapıda olması nedeniyle gömülü boyut değeri sağlıklı bir şekilde saptanamamaktadır.

BÖLÜM DÖRT

SONUÇLAR

Bu çalışmada son yıllarda fen ve mühendislik alanında da yaygın olarak kullanılan Yapay Sinir Ağları yöntemi, jeofizik verilere uygulanmıştır. Yapay Sinir ağlarına dışarıdan verilen bilgiler (girdi) ağırlıklar yardımıyla nöronlara iletilir. Aktivasyon fonksiyonundan geçirilen veriler sistemin çıktısını meydana getirmektedir. Yapay Sinir Ağlarında farklı özellikler taşıyan ağ türleri bulunmaktadır. Tez kapsamında öğretmenli öğrenme temeline dayanan Çok katmanlı algılayıcı ve Radyal Taban Fonksiyonlu Ağlar kullanılmıştır. Bu tür ağlar farklı olayların örneklerine bakmakta onlardan ilgili olay hakkında genelleme yapmakta, bilgiler toplamakta ve daha sonra hiç görmediği örnekler ile karşılaştınca öğrendiği bilgileri kullanarak o örnekler hakkında karar verebilmektedir. Böylece eğitim setindeki bir çok modelden yararlanarak problem için en iyi çözümü elde etmek yöntemin önemli avantajıdır. Yapay sinir ağlarında eğitim seti oluşturmak için fazla veriye ihtiyaç duyulması ve sistemin öğrenme aşamasının uzun sürmesi bu yöntemin dezavantajlarından. Çok katmanlı algılayıcı ve Radyal Taban Fonksiyonlu ağlar öncelikle kuramsal gravite modellerine ve Batı Anadolu nun en önemli tektonik yapılarından olan Gediz ve Büyük Menderes grabenlerinin tortul kalınlığını saptamak amacıyla, Batı Anadolu Bouguer gravite verilerine uygulanmıştır. Yöntemin zaman serilerindeki performansını test etmek amacıyla çalışmasının ikinci aşamasında Batı Anadolu deprem katalog verilerinin aylık frekans ön kestiriminde kullanılmıştır.

Çalışma kapsamında Çok katmanlı Algılayıcı ve Radyal Taban fonksiyonlu Ağlar kullanılarak Gediz grabeni için üç farklı gravite profilinin sonuçları incelendiğinde Salihli yakınlarından alınan GB-KD doğrultulu iki profil için elde edilen derinlik değerleri yaklaşık 1,4 ve 2 km dir. Grabenin Alaşehir civarında alınan üçüncü profil için tortul kalınlığının yaklaşık 2,5 km olduğu saptanmıştır. Aynı alanda daha önce yapılmış jeofizik çalışmalar ve açılan araştırma sondajları incelendiğinde elde edilen tortul kalınlığının bu veriler ile uyumlu olduğu gözlenmiştir. Graben için tüm

profillerin sonuçları incelendiğinde ise tortul kalınlığının batıdan doğuya doğru arttığı ve grabenin asimetrik bir yapıda olduğu gözlenmektedir.

Büyük Menderes grabeni için ikisi GB-KD biri K-G yönlü üç gravite profili değerlendirilmiştir. Aydın civarından alınan GB- KD doğrultulu ilk profil için yaklaşık 1,7 km tortul kalınlığı saptanmıştır. Nazilli civarından alınan K-G uzanımlı ikinci profil için elde edilen kalınlık değeri yaklaşık 2,2 km'dir. GB-KD uzanımlı üçüncü profil Sarayköy civarından alınmıştır. Bu bölge için elde edilen kalınlık değeri yaklaşık 3,2 km'dir. Büyük Menderes grabeni üzerinde daha önce yapılmış jeofizik çalışmalar ile Yapay Sinir ağları sonuçlarının uyumlu olduğu görülmüştür. Graben için Yapay Sinir Ağları ile elde edilen tüm sonuçlar incelendiğinde grabenin tortul kalınlığının batıdan doğuya gidildikçe arttığı ve grabenin asimetrik bir yapıda olduğu gözlenmektedir.

Batı Anadolu da önemli jeotermal alanlardan biri olan Seferihisar bölgesinde alınan gravite profilinin ÇKA ve RTFA ile değerlendirilmesi sonucunda elde edilen tortul kalınlığı 1,5 ve 1,7 km olarak saptanmıştır. Bölgede yapılmış jeofizik çalışmalar ve sondaj verileri ile Yapay Sinir Ağları sonuçlarının uyumlu olduğu gözlenmektedir.

Çok katmanlı Algılayıcı ve Radyal Taban Fonksiyonlu Ağlar ayrıca Batı Anadolu nun kabuk kalınlığını saptamak amacıyla gravite verilerine uygulanmıştır. Bölgede alınmış K-G uzanımlı bir profilin değerlendirilmesi sonucunda kabuk kalınlığı yaklaşık 32 km olarak saptanmıştır.

Bölgede meydana gelen depremlerin dinamik davranışlarını analiz etmek için deprem katalog verileri ÇKA ve RTFA ile değerlendirilmiştir. Bölgede meydana gelen magnitüdü 3 ve 3 ten büyük depremlerin aylık frekans ön kestirimleri sonucunda ÇKA ile elde edilen sonuçların korelasyon katsayısı 0,08- 0,38 arasında değişirken, RTFA ile elde edilen sonuçlar için korelasyon katsayıları 0,30- 0,93 arasında değerler almaktadır. Girdi sayıları değiştirilerek elde edilen her durum incelendiğinde, girdi sayısının 2, 3, 4 ve 5 olduğu durumlarda elde edilen ön kestirim değerlerinin gerçek değerlerle daha uyumlu olduğu gözlenmektedir. ÇKA sonuçları

incelenirse, 4 girdili durumda en yüksek korelasyon katsayısı ve düşük hata değeri elde edilmiştir. RTFA uygulamasında ise 2 girdili durumda korelasyon katsayısı 0,93 olan en yüksek değere ulaşmış ve en düşük hata değeri elde edilmiştir. Her iki yöntemin sonuçları incelendiğinde, bölgedeki deprem aylık ön kestirim değerlerinin RTFA türü ile ÇKA göre daha başarılı olduğu gözlenmektedir.

KAYNAKLAR

- Ahl, A. (2003). Automatic 1D inversion of multifrequency airborne electromagnetic data with artificial neural Networks: discussion and a case study. *Geophysical Prospecting*, 51, 89-97.
- Akçığ, Z. (1985). Batı Anadolu 'nun Yapısal Sorunlarının Gravite Verileri ile İrdelenmesi. *Türkiye Jeoloji Kurultayı bildiri özleri*, 32, Ankara.
- Albora, A. M., Özmen, A., ve Uçan, O. N. (2001) . Residual separation of magnetic fields Using a Cellular Neural network Approach. *Pure and Applied Geophysics*, 158, 1797-1818.
- Albora, A. M., Ucan, O. N., Özmen, A., ve Özkan, T. (2001). Separation of Bouguer anomaly map using cellular neural network. *Journal of Applied Geophysics*, 46, 129-142.
- Albora, A. M. ve Uçan, O. N. (2005). Kuşaklı Hitit uygarlığına ait arkeolojik kalıntıların hücreli yapay sinir ağı (HYSA) kullanılarak görüntülenmesi. *Jeoarkeoloji ve Arkeojeofizik Sempozyumu*, 101-105.
- Allameh Zadeh, M., 2004. Prediction of aftershocks pattern distribution using self-organising feature maps. *13 th World conference on earthquake engineering*, 198.
- Aydoğan, D., Ucan, O. N., Albora, A. M., ve Elmas, A. (2003). A new approach to tectonics structure of Aegean Sea: Cellular Neural Network (CNN). *International Conference on Earth Sciences and Electronics*.
- Baddari, K., Aifa, T., Djarfour, N., Ferahtia, J. (2009). Application of a radial basis function artificial neural network to seismic data inversion. *Computers & Geosciences*, 35, 2338–2344

Bayındırlık ve İskan Bakanlığı Afet İşleri Genel Müdürlüğü Deprem Araştırma Dairesi. Deprem katalog verileri.

Bodri, B. (2001). A neural network model for earthquake occurrence. *Journal of Geodynamics*, 32, 289-310.

Boğaziçi Üniversitesi, Kandilli Rasathanesi ve Deprem Araştırma Enstitüsü. Deprem katalog verileri.

Bozkurt, E. (2000). Timing of Extension on the Büyük Menderes Graben, Western Turkey and its tectonic implications. In: Bozkurt, E., Winchester, J.A., Piper, J.D.A. (Eds.), *Tectonics and Magmatism in Turkey and the Surrounding Area. Geological Society, London, Special Publications* 173, 385–403.

Bozkurt, E. ve Sözbilir, H. (2004). Tectonic evolution of the Gediz Graben: field evidence for an episodic, two-stage extension in western Turkey. *Geological Magazine*, 141, 63–79.

Cohen, H.A., Dart, C.J., Akyüz, H.S. ve Barka, A. (1995). Syn-rift sedimentation and structural development of the Gediz and Büyük Menderes graben, western Turkey. *Journal of Geological Society, London*, 152, 629–638.

Çiftçi, N., B. ve Bozkurt, E. (2009). Evolution of the Miocene sedimentary fill of the Gediz Graben, SW Turkey. *Sedimentary Geology*, 216, 49–79.

Dai, H., MacBeth, C. (1996). Arrival type identification in local earthquake data using an artificial neural network. *Cahiers du Centre Européen de Géodynamique et de Séismologie*. Vol. 12.

Dewey, J.F. ve Şengör, A.M.C. (1979). Aegean and surrounding regions: complex multiple and continuum tectonics in a convergent zone. *Geological Society of America Bulletin*, 90, 84–92.

- Dewey, J.D. (1988). Extensional collapse of orogens. *Tectonics*, 7, 1123–1139.
- Drahor, M.G., C. Sarı, ve M. Şalk (1999). Seferihisar Jeotermal alanında Doğal Gerilim (SP) ve Gravite Çalışmaları *Dokuz Eylül Üniversitesi, Mühendislik Fakültesi, Fen ve Mühendislik Dergisi*, Cilt: 1 Sayı: 3 , 97-112
- El-Qady, G. ve Ushijima, K. (2001). Inversion of DC resistivity data using neural networks. *Geophysical Prospecting*, 49, 417-430.
- Emre, T. ve Sözbilir, H. (1995). Field evidence for metamorphic core complex, detachment faulting and accommodation faults in the Gediz and Büyük Menderes grabens, western Anatolia. In: Pişkin, Ö., Ergün, M., Savaşın, M.Y., Tarcan, G. (Eds.), *International Earth Sciences Colloquium on Aegean Regions (IESCA) Proceedings*, 1, 73–93.
- Emre, T. (1996). Gediz Grabeninin jeolojisi ve tektonigi. *Turkish Journ. of Earth Sciences*, v.5, 171-186
- Essenreiter, R., Karrenbach, M. ve Treitel, S. (2001). Identification and classification of multiple reflections with self-organizing maps. *Geophysical Prospecting*, 49, 341-352.
- Essenreiter, R., Karrenbach, M. ve Treitel, S. (2003). Identification and suppression of multiple reflections in marine seismic data with neural Networks. W. Sandham and M. Leggett Editors, *Geophysical Applications of Artificial Neural Networks and Fuzzy Logic*, Kluwer Academic Publishers, Boston, London.
- Ezen, Ü. (1991). Crustal structure of western Turkey from Rayleigh wave dispersion: *Bulletin of International Institute of Seismology and Earthquake Engineering*, 25, 1-21.

- FitzGerald, M. E., Bean, J. C. ve Reilly, R.(1999). Fracture-frequency prediction from borehole wireline logs using artificial neural networks. *Geophysical Prospecting*, 47, 1031-1044.
- Goutorbe, B., Lucazeau, F. ve Bonneville, A.(2006). Using neural Networks to predict thermal conductivity from geophysical well logs. *Geophysical Journal International*, 166,115-125.
- Göktürkler, G., Şalk, M. ve Sarı, C.(2003). Numerical modelling of the conductive heat transfer in western Anatolia. *Journal of Balkan Geophysical Society* 6, 1–15.
- Grant F.S. ve West, G.F.(1965). *Interpretation Theory in Applied Geophysics*, NewYork.
- Grossberg, S.(1988a). Competitive learning: From interactive activation to adaptive resonance. In *Neural Networks Intelligence*, S. Grossberg, ed., Cambridge, MA: MIT Press.
- Grossberg, S.(1988b). *Neural Networks and Natural Intelligence*, Cambridge, MA: MIT Press.
- Grossberg, S.(1988c). Nonlinear neural networks: Principles, mechanisms, and architectures. *Neural Networks*, 1, 17-61.
- Gürer, A., Pinçe, A., Gürer, Ö .F. ve İlkışık, O.M. (2002). Resistivity distribution in the Gediz graben and its implications for crustal structure. *Turkish Journal of Earth Sciences*, 11, 15–25.
- Haataja, J. (1999). Using Genetic Algorithms for Optimization: Technology Transfer in Action. in *Evolutionary Algorithms in Engineering and Computer Science*, Edited by Miettinen, K., Makela, M.M., Neittaanmaki, P., & Periaux, J., Wiley, Chichester. 3–22.

- Ham, M.F. ve Kostanic, I. (2000). Principles of Neurocomputing for Science & Engineering. *McGraw-Hill*,
- Haykin, S. (1999). *Neural Network: A Comprehensive Foundation*, (2. Baskı). Prentice Hall, New Jersey, USA.
- He, Q., ve Zhou, H. (2003). Application of artificial neural Networks to seismic waveform inversion. W. Sandham and M. Leggett Editors, *Geophysical Applications of Artificial Neural Networks and Fuzzy Logic*, Kluwer Academic Publishers, Boston, London.
- Hebb, D.O., (1949). The organization of Behavior: A Neuropsychological Theory, New York: Wiley.
- Hele, H. B., Bhatt, A. ve Ursin, B. (2001). Porosity and permeability prediction from wireline logs using artificial neural Networks: a North Sea case study. *Geophysical Prospecting*, 49, 431-444.
- Hinton, G., E. ve Sejnowski, T., J.(1986). Learning and relearning in Boltzmann machines. In parallel Distributed Processing: Explorations in Microstructure of Cognition, D.E. Rumelhart and J.L. McClelland, eds, Cambridge, MA: MIT Press.
- Hopfield, J., J.(1982). Neural networks and physical systems with emergent collective computational abilities, Proceedings of the National Academy of Sciences, USA, vol. 79 2554-2558.
- Hopfield, J., J.(1984). Neurons with graded response have collective computational properties like those of two-state neurons, Proceedings of the National Academy of Sciences, USA, vol. 81, 3088-3092.

- Işık, M. ve Şenel, H. (2009). 3D gravity modeling of Büyük Menderes basin in Western Anatolia using parabolic density function. *Journal of Asian Earth Sciences* 34, 317–325.
- Işık, M. (1997). Değişken Yoğunluklu Sedimanter Basen Anomalilerinin Ters Çözümü. *Doktora tezi*, Kocaeli Üniv. Fen Bil.Ens., Kocaeli.
- Jackson, J.A. ve Mckenzie, D. (1984). Active tectonics of the Alpine-Himalayan belt between western Turkey and Pakistan. *Geophysical Journal of the Royal Astronomical Society* 77, 185-264.
- James, W., (1890). Psychology (Briefer Course). New York: *Holt. Chapter XVI, Association*, 253-279.
- Kerh, T. ve Chu, D. (2002). Neural Networks approach and microtremor measurements in estimating peak ground acceleration due to strong motion. *Advances in Engineering Software*, 33, 733-742.
- Ketin, Y. (1968). Türkiye'nin genel tektonik durumu ile başlıca deprem bölgeleri arasındaki iliksiler. *MTA Enst. Dergisi*, 71, 129-134.
- Koçyigit, A.(1984). Güneybatı Türkiye ve yakın dolayında levha içi yeni tektonik Gelisim. *TJK Bült.*, 24/1, 1-16.
- Koçyigit, A., Yusufoglu, H., Bozkurt, E.(1999). Evidence from the Gediz Graben for episodic two-stage extension in western Turkey. *Journal of the Geological Society, London*, 156, 605–616
- Koçyigit, A., Ünay, E. ve Saraç, G. (2000). Episodic graben formation and extensional neotectonic regime in west Central Anatolia and the Isparta Angle: a case study in the Akşehir-Afyon Graben, *Turkey. Geol. Soc. London, Spec. Pbl.* 173. 405-421.

- Kohonen, T., (1982). Self-organized formation of topologically correct feature maps. *Biological Cybernetics*, vol. 43, 59-69.
- Last , B.J. ve Kubik, K., (Haziran 1983). Compact gravity inversion. *Geophysics*, 48, No. 6.
- Le Pichon, X. ve Angelier, J. (1979). The Hellenic arc trench system: a key to neotectonic evolution of the eastern Mediterranean area. *Tectonophysics* 60, 1–42.
- Lips, A.L.W., Cassard, D., Sözbilir, H. ve Yılmaz, Y. (2001). Multistage exhumation of the Menderes Massif, western Anatolia (Turkey). *International Journal of Earth Sciences*, 89, 781–792.
- Luongo, G., Marandola, C. Ve Mazzarella, A.(2004). Neural forecasting of seismicity and ground displacements in different volcanic areas. *Journal of Volcanology and Geothermal Research*, 130, 133-146.
- Macias, C. C., Sen, M. K. ve Stoffa, P. L.(1998). Automatic NMO correction and velocity estimation by a feedforward neural network. *Geophysics*, Vol. 63, No. 5 1696-1707.
- Macias, C. C., Sen, M. K. ve Stoffa, P. L. (2000). Artificial neural network for parameter estimation in geophysics. *Geophysical Prospecting*, 48, 21-47.
- Maden Tetkik Arama, (1979). Bouguer Gravite Anomali Haritası (Yayınlanmamış).
- Manoj, C. ve Nagarajan, N. (2003). The application of artificial neural networks to magnetotelluric time-series analysis. *Geophys. J. Int.* 153, 409-423.

- McClusky, S., Balassanian, S., Barka, A., Demir, C., Ergintav, S., Georgiev, I., Gurkan, O., Hamburger, M., Hurst, K., Kahle, H., Kastens, K., Kekelidze, G., King, R., Kotzev, V., Lenk, O., Mahmoud, S., Mishin, A., Nadariya, M., Ouzounis, A., Paradissis, D., Peter, Y., Prilepin, P., Reilinger, P., Sanli, I., Seeger, H., Tealeb, A., Toksöz, M.N. ve Veis, G. (2000). Global Positioning System constraints on plate kinematics and dynamics in the Eastern Mediterranean and Caucasus. *Journal of Geophysical Research*, 105, B3, 5695–5719.
- McCulloch, W.S., ve Pitts, W. (1943). A logical calculus of the ideas immanent in nervous activity, *Bulletin of Mathematical Biophysics*, vol. 5, 115-133.
- Mckenzie, D. P. (1972). Active tectonics of the Mediterranean region. *Geophysical Journal of the Royal Astronomical Society*, 30, 109-185
- McKenzie, D.P. (1978). Active tectonics of the Alpine-Himalayan Belt: The Aegean sea and its surrounding regions. *Geophys. J. R. Astr. Soc.*, 55, 217-254.
- Meulenkamp, J.E., Wortel, M.J.R., Van Vamel, W.A., Spakman, W. ve Hoogerduynstrating, E. (1988). On the Hellenic subduction zone and the geodynamic evolution of Crete since the late middle Miocene. *Tectonophysics*, 146, 203–215.
- Mindevalli, O. Y., and Mitchell, B. J., 1989, Crustal Structure and possible anisotropy in Turkey from seismic surface-wave dispersion: *Geophys.J.Int.*,98, 93-106.
- Minsky, M. ve Papert, S. (1969). *Perceptrons*: MIT Pres.

- Okay, A.I., Kaşlılar-Özcan, A., İmren, C., Boztepe-Güney, A., Demirbeğ, E. ve Kuşçu, İ. (2000). Active faults and evolving strike-slip basins in the Marmara Sea, northwest Turkey: a multichannel seismic reflection study, *Tectonophysics*, 321: 189-218.
- Osman, O., Albora, A.M. ve Ucan, O.N. (2007). Forward modelling with forced Neural Networks for gravity anomaly profile. *Mathematical Geology*, 39, 593-605.
- Öztemel, E., (2003). Yapay Sinir Ağları, Papatya Yayıncılık, İstanbul , Türkiye.
- Paton, S. (1992). Active normal faulting, drainage patterns and sedimentation in southwestern Turkey. *Journal of the Geological Soc. of London*, 149, 1031-1044.
- Plummer, E.A.(2000). Time Series Forecasting With Feed-Forward Neural Networks:Guidelines and Limitations. Master Of Science in Computer Science.
- Powell, M., J., D. (1985). Radial basis functions for multivariable interpolation: A review. IMA Conference on Algorithms for the Approximation of Functions and Data, 143-167, Shrivenham, England.
- Poulton, M. M., Sternberg, B. K. ve Glass, C. E. (1992). Location of subsurface targets in geophysical data using neural Networks. *Geophysics*, 57(12), 1534-1544.
- Poulton, M. M.(2001). Computational Neural Networks for Geophysical Data Processing..*Handbook of Geophysical Exploration* Volume 30, Pergamon.
- Purvis, M., ve Robertson, A.H.F. (2005). Sedimentation of the Neogene–Recent Alasehir (Gediz) continental graben system used to test alternative tectonic models for western (Aegean) Turkey. *Sedimentary Geology*, 173, 373–408.

- Rosenblatt, F.(1958). The Percetron: A probabilistic model for information storage and organization in the brain. *Psychological Review*, Vol. 65, 386-408.
- Rumelhart, D., E. ve McClelland, J., L. (1986). *Parallel Distributed Processing: Explorations in the Microstructure of Cognition*, Vol.1 Cambridge, MA: MIT Press.
- Rumelhart, D.,E., Hinton, G., E. ve Williams, R.,J. (1986a). Learning representations of back-propagation errors. *Nature (London)*, Vol., 323, 533-536.
- Rumelhart, D.,E., Hinton, G., E. ve Williams, R.,J. (1986b). Learning internal representations by error propagation. In D.,E. Rumelhart and and J.L. McClelland, eds, Vol 1, Chapter 8, Cambridge, MA: MIT Press.
- Sađırođlu., Ő., BeŐdok, E. ve Erler, M. (2003). Mühendislikte Yapay Zeka Uygulamaları. *Ufuk Kitabevi*.
- Sarı, C. ve Őalk, M. (2006). Sediment thicknesses of the Western Anatolia graben structures determined by 2D and 3D analysis using gravity data. *Journal of Asian Earth Sciences*, 26, 39–48.
- Seyitođlu, G. ve Scott, B. (1992) . The age of the Büyük Menderes graben (west Turkey) and its tectonic implications. *Geological Magazine*, 129, 239–242.
- Seyitođlu, G. ve Scott, B.C. (1996). The age of the AlaŐehir graben (west Turkey) and its tectonic implications. *Geological Journal*, 31, 1-11.
- Simon, H. A., (1983). Why should machines Learn? In: *Machine Learning- An Artificial Intelligence Approach*. Michalski, R. S., Carbonell, J. G., & Mitchell, T. M. (Ed). Palo Alto, California: Tioga.

- Sözbilir, H. (2001). Geometry of macroscopic structures with their relations to the extensional tectonics: field evidence from the Gediz detachment, Western Turkey. *Turkish Journal of Earth Sciences*, 10, 51–67.
- Sözbilir, H. (2002). Geometry and origin of folding in the Neogene sediments of the Gediz Graben, Western Anatolia, Turkey. *Geodinamica Acta*, 15, 277–288.
- Sri Lakshmi, S. ve Tiwari, R.K.(2009). Model dissection from earthquake time series: A comparative analysis using modern non-linear forecasting and artificial neural network approaches. *Computers & Geosciences*, 35, 191-204.
- Şalk, M., Altıner, Y. Ve Ergün, M. (1999). Geodynamics of Western Turkey. *Proceedings of the International Conference on Earthquake Hazard and Risk in the Mediterranean Region*. V.II, 179–188, 18–22, Turkish Republic of Northern Cyprus.
- Şenel, H. (1997). Inversion of gravity anomaly of Büyük Menderes faults. *Journal of Kocaeli University* 4, 66–72.
- Şenel, H., ve Işık, M. (2009). 3D gravity modeling of Büyük Menderes basin in Western Anatolia using parabolic density function. *Journal of Asian Earth Sciences*, 34, 317-325.
- Şengör, A. M. C.(1979). The North Anatolian Transform Fault: its age, offset and tectonic significance: *Journal of Geological Society, London*, 13, 268- 282.
- Şengör, A. M. C.(1980). Mesozoic-Cenozoic tectonic evolution of Anatolia and surrounding regions: *Bureau de Recherches Geologiques et Minières Bulletin*, 115-117.

- Şengör, A.M.C., Satır, M.G. ve Akkök, R. (1984). Timing of tectonic events in the Menderes massif, Western Turkey: Implications for tectonic evolution and evidence for Pan-African basement in Turkey. *Tectonics*, 3, 693-707
- Şengör, A. M. C., Görür, N. ve Şaroglu, F.(1985). Strike-slip deformation basin formation and sedimentation: Strike-slip faulting and related basin formation in zones of tectonic escape: Turkey as a case study: *Society of Economic Paleontologists and Mineralogists, Special Publication*, 37, 227-264.
- Şengör, A.M.C. (1987). Cross faults and differential stretching of hanging walls in regions of low-angle normal faulting: Examples from western Turkey, in: Coward M.P., Dewey J.F. and Hancock P.L. eds. Continental extensional tectonics. *Geological Society Special Publication*, 28, 575-589.
- Şengör, A.M.C.(1987). Cross-faults and differential stretching of hanging walls in regions of low-angle normal faulting: examples from western Turkey, in: Coward, M.P., Dewey, J.F., Hancock, P.L. (Eds.), Continental Extensional Tectonics Geological Society Special Publication No: 28, *Geological Society, London*, 575–589.
- Ucan, O. N., Bilgili, E., Albora, A. M. (2002). Magnetic anomaly separation using Genetic Cellular Neural Networks. *Journal of the Balkan Geophysical Society*, 5, 3, 65-70.
- Van der Baan, M. ve Jutten, C. (2000). Neural Networks in geophysical applications. *Geophysics*, 65(4), 1032-1047.
- Wang, L. Ve Mendel, J. M. (1992). Adaptive minimum prediction-error deconvolution and source wavelet estimation using Hopfield neural network. *Geophysics*, 57(4), 670-679.

- Widrow, B., ve Hoff, M. E. (1960). Adaptive switching circuits. *IRE WESCON Convention Record*, 96-104.
- Yazman, M., Yılmaz, M., İztan, H., Batı, Z. ve Sayılı, A. (1998). Alaşehir Grabeni ve Prospektinin değerlendirme raporu, *TPAO Arama Grubu 3864 Nolu Rapor*, Ankara
- Yılmaz, M.(2003). İnteraktif Sistemlerde Alaşehir Grabeninin Sismik Atribütler Kullanılarak Yapısal-Stratigrafik Yorumu ve Hidrokarbon Potansiyelinin Araştırılması. Doktora Tezi. Karadeniz Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Jeofizik Mühendisliği Anabilimdalı.
- Zhang, Y. ve Paulson, K. V. (1997). Magnetotelluric inversion using regularized Hopfield neural Networks. *Geophysical Prospecting*, 45, 725-743.