

**JEODEZİK NOKTA HIZ KESTİRİMİNDE
YAPAY SİNİR AĞLARININ
KULLANILABİLİRLİĞİ**

DOKTORA TEZİ

Mustafa YILMAZ

DANIŞMAN

Yrd. Doç. Dr. Mevlüt GÜLLÜ

JEODEZİ VE FOTOGRAMETRİ MÜHENDİSLİĞİ

Mayıs, 2012

Bu tez çalışması 11.FEN.BİL.23 numaralı proje ile Afyon Kocatepe Üniversitesi
Bilimsel Araştırma Projeleri Koordinasyon Birimi tarafından desteklenmiştir.

AFYON KOCATEPE ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

DOKTORA TEZİ

JEODEZİK NOKTA HIZ KESTİRİMİNDE
YAPAY SİNİR AĞLARININ KULLANILABİLİRLİĞİ

Mustafa YILMAZ

DANIŞMAN

Yrd. Doç. Dr. Mevlüt GÜLLÜ

JEODEZİ VE FOTOGRAMETRİ MÜHENDİSLİĞİ

Mayıs, 2012

TEZ ONAY SAYFASI

Mustafa YILMAZ tarafından hazırlanan “Jeodezik Nokta Hız Kestiriminde Yapay Sinir Ağlarının Kullanılabilirliği” adlı tez çalışması lisansüstü eğitim ve öğretim yönetmeliğinin ilgili maddeleri uyarınca, 28 / 05 / 2012 tarihinde aşağıdaki jüri tarafından oy birliği/oy çokluğu ile Afyon Kocatepe Üniversitesi Fen Bilimleri Enstitüsü **Jeodezi ve Fotogrametri Mühendisliği Anabilim Dalı’nda DOKTORA TEZİ** olarak kabul edilmiştir.

Danışman : Yrd. Doç. Dr. Mevlüt GÜLLÜ

Başkan	: Doç. Dr. Semih EKERCİN Aksaray Üniversitesi, Mühendislik Fakültesi,	İmza
Üye	: Doç. Dr. Aydın ÜSTÜN Selçuk Üniversitesi, Mühendislik Mimarlık Fakültesi,	İmza
Üye	: Yrd. Doç. Dr. Mevlüt GÜLLÜ Afyon Kocatepe Üniversitesi, Mühendislik Fakültesi,	İmza
Üye	: Yrd. Doç. Dr. Mustafa ACAR Aksaray Üniversitesi, Mühendislik Fakültesi,	İmza
Üye	: Yrd. Doç. Dr. Ekrem TUŞAT Selçuk Üniversitesi, Mühendislik Mimarlık Fakültesi,	İmza

Afyon Kocatepe Üniversitesi
Fen Bilimleri Enstitüsü Yönetim Kurulu’nun
...../...../..... tarih ve
..... sayılı kararıyla onaylanmıştır.

.....
Enstitü Müdürü
Prof. Dr. Mevlüt DOĞAN

BİLİMSEL ETİK BİLDİRİM SAYFASI
Afyon Kocatepe Üniversitesi

Fen Bilimleri Enstitüsü, tez yazım kurallarına uygun olarak hazırladığım bu tez çalışmada;

- Tez içindeki bütün bilgi ve belgeleri akademik kurallar çerçevesinde elde ettiğimi,
- Görsel, işitsel ve yazılı tüm bilgi ve sonuçları bilimsel ahlak kurallarına uygun olarak sunduğumu,
- Başkalarının eserlerinden yararlanılması durumunda ilgili eserlere bilimsel normlara uygun olarak atıfta bulunduğumu,
- Atıfta bulunduğum eserlerin tümünü kaynak olarak gösterdiğimi,
- Kullanılan verilerde herhangi bir tahrifat yapmadığımı,
- Tezin herhangi bir bölümünü bu üniversite veya başka bir üniversitede başka bir tez çalışması olarak sunmadığımı,

beyan ederim.

28 / 05 / 2012

Mustafa YILMAZ

ÖZET
Doktora Tezi

**JEODEZİK NOKTA HIZ KESTİRİMİNDE
YAPAY SİNİR AĞLARININ KULLANILABİLİRLİĞİ**

Mustafa YILMAZ
Afyon Kocatepe Üniversitesi
Fen Bilimleri Enstitüsü
Jeodezi ve Fotogrametri Mühendisliği Anabilim Dalı
Danışman: Yrd. Doç. Dr. Mevlüt GÜLLÜ

Uydu konumlama sistemlerindeki teknolojik gelişmelere ve hızla artan Global Konum Belirleme Sistemi (GPS) tekniği kullanımına paralel olarak, Harita Genel Komutanlığı (HGK) tarafından güncel jeodezik gereksinimlerin karşılanması amacıyla Türkiye Ulusal Temel GPS Ağı (TUTGA) oluşturulmuştur. TUTGA'nın zaman boyutlu jeodezik tasarımı nedeniyle, Türkiye'nin üzerinde bulunduğu aktif tektonik yapının jeodezik nokta koordinatlarında sebep olduğu değişimlerin dikkate alınması için TUTGA noktalarında farklı oturumlarda gerçekleştirilen GPS ölçmelerinin aynı referans epokunda değerlendirilmesi gerekmektedir. Ayrıca, TUTGA'nın kurulmasına paralel olarak 2005 yılında yürürlüğe giren Büyük Ölçekli Harita ve Harita Bilgileri Üretim Yönetmeliği (BÖHKBÜY), TUTGA bünyesinde oluşturulacak sıklaştırma ağ noktalarının koordinatlarının, belirlenmiş bir referans epokuna göre elde edilmesini gerektirmektedir. Söz konusu işlemler, TUTGA noktalarının koordinatları ile birlikte hız vektörlerine (V_X , V_Y , V_Z) ihtiyaç duymaktadır. Mevcut uygulamalarda iki veya daha fazla GPS oturumu ile hızları iyi olarak belirlenmiş TUTGA noktalarının hız vektörlerinden diğer TUTGA noktalarının hızları kestirilmek suretiyle TUTGA hız alanı oluşturulmaktadır. Sıklaştırma ağlarında ise tesis edilen noktaların hızları TUTGA noktalarının veya daha yüksek dereceli sıklaştırma noktalarının hızları kullanılarak enterpolasyon yöntemleri ile hesaplanmaktadır.

Bu çalışmada geçtiğimiz yüzyılın son çeyreğinden itibaren, gelişen bilgisayar sistemlerine paralel olarak, farklı disiplinler tarafından birçok bilim ve mühendislik

alanında kestirim, modelleme, sınıflandırma, tahmin, doğrusal olmayan regresyon gibi çalışmalarda yaygın olarak uygulanmaya başlanan Yapay Sinir Ağlarının (YSA), jeodezik nokta hızlarının kestirimi probleminde kullanılabilirliği araştırılmıştır. HGK tarafından belirlenmiş TUTGA noktalarına ait hız değerleri temel alınarak, YSA'nın en çok kullanılan iki modeli olan Geri Yayılımlı Yapay Sinir Ağı (GYRSA) ve Radyal Bazlı Fonksiyon Sinir Ağı (RBFSA) ile jeodezik nokta hızları hesaplanmıştır. GYRSA ve RBFSA'nın performansını değerlendirebilmek amacıyla HGK tarafından TUTGA hız alanının belirlenmesinde kullanılan Kriging (KRIG) enterpolasyon yöntemi ile de hız kestirimi yapılarak elde edilen sonuçlar karesel ortalama hata (KOH) ölçütü kullanılarak karşılaştırılmıştır. Çalışma alanı olarak Türkiye'nin orta ve batı Anadolu bölümlerinde yer alan toplam 125 adet TUTGA noktası seçilmiş ve nokta yoğunluğunun sonuçlara olan etkisini değerlendirebilmek amacıyla söz konusu 125 adet nokta ile beş farklı jeodezik ağ oluşturularak hız kestirimleri gerçekleştirilmiştir. Referans olarak kullanılan nokta sayısının, hızları hesap edilecek (test) nokta sayısından az olduğu jeodezik ağlarda GYRSA'nın KRIG yönteminden daha iyi sonuçlar verdiği, RBFSA'nın ise referans nokta sayısının en az olduğu jeodezik ağda KRIG yöntemiyle aynı hassasiyette sonuç verdiği tespit edilmiştir. Hızları bilinen nokta sayısının, hızları hesaplanacak nokta sayısından daha az olduğu kestirim problemlerinde, GYRSA kullanımı ile KRIG yönteminin kullanımından daha etkin ve doğru bir şekilde jeodezik noktaların hız vektörlerinin hesaplanabileceği değerlendirilmiştir.

2012, xii + 90 sayfa

Anahtar Kelimeler: TUTGA, Jeodezik ağ, Nokta hız kestirimi, Yapay sinir ağları, Geri yayılım, Radyal bazlı fonksiyon, Kriging

ABSTRACT
Ph.D. Thesis

THE UTILITY OF ARTIFICIAL NEURAL NETWORKS IN
GEODETIC POINT VELOCITY ESTIMATION

Mustafa Yılmaz
Afyon Kocatepe University
Graduate School of Natural and Applied Sciences
Department of Geodesy and Photogrammetry Engineering
Supervisor: Assist. Prof. Mevlüt Güllü

Turkish National Fundamental GPS Network (TNFGN) has been established in order to cover the current geodetic needs by General Command of Mapping (GCM) in parallel with the technological developments in satellite positioning systems and the rapidly growing in the use of Global Positioning System (GPS) techniques. Due to the geodetic design of TNFGN with time dimension, the GPS measurements performed in different sessions are required to process with the same reference epoch for consideration of the coordinate displacements of geodetic points caused by the active tectonic structure of Turkey. Furthermore, Large Scale Map and Map Information Production Regulation (LSMMIPR) that came into force in 2005 in parallel with the establishment of TNFGN requires obtaining the coordinates of the densification network points to be created within TNFGN according to the specified reference epoch. These transactions require the velocity vectors (V_x , V_y , V_z) besides the coordinates of TNFGN points. In the present applications, the velocity field of TNFGN is generated by estimating the velocities of TNFGN points from the velocity vectors of other TNFGN points that are determined by two or more GPS sessions. In the densification networks, the velocities of the constructed points are estimated from the velocities of TNFGN points or from higher order densification points by interpolation methods.

In this study, the utility of Artificial Neural Networks (ANN) that have been widely applied in diverse fields of science and engineering by various disciplines for

estimation, modelling, classification, prediction, nonlinear regression since the last quarter of the passed century, is investigated for the problem of estimating the geodetic points velocities. The geodetic point velocities are estimated with Back Propagation Artificial Neural Network (BPANN) and Radial Basis Function Neural Network (RBFNN) that have been more widely applied among all other ANN applications by using the velocity information that are determined by GCM as fundamental values. In order to evaluate the performance of BPANN and RBFNN, the velocities are also estimated by Kriging (KRIG) interpolation method that is used by GCM in determining the velocity field of TNFGN and the results are compared in terms of the root mean square error (RMSE). 125 TNFGN points that are located in central and western Anatolian parts of Turkey are selected as the study area and the velocities are estimated on five different geodetic networks that were generated to assess the impact of the point density on the results. In the geodetic networks that the reference points are less than the test points, BPANN gave more accurate results than KRIG. RBFNN gave approximately same accuracy results with KRIG in the geodetic network with the least reference points. When the number of the points that will be estimated are smaller than the number of the points that are estimated, the estimation of geodetic point velocity with the use of BPANN is evaluated to be more effective and accurate than using KRIG.

2012, xii + 90 pages

Key Words: TNFGN, Geodetic network, Point velocity estimation, Artificial neural networks, Back propagation, Radial basis function, Kriging

TEŞEKKÜR

Doktora çalışmamın her aşamasındaki destek ve önerileri ile yapmış olduğu katkılarından dolayı danışman hocam Sayın Yrd. Doç. Dr. Mevlüt GÜLLÜ (Afyon Kocatepe Üniversitesi)'ye, tez çalışmam sırasındaki öneri ve eleştirileriyle yardımlarını gördüğüm tez izleme komitesindeki hocalarım Sayın Doç. Dr. Semih EKERCİN (Aksaray Üniversitesi)'e ve Sayın Yrd. Doç. Dr. Mustafa ACAR (Aksaray Üniversitesi)'a, tez çalışmamın uygulama verilerini sağlayan arkadaşım Sayın Hrt. Yük. Müh. Ömer SALGIN (Tapu ve Kadastro Genel Müdürlüğü)'a, literatür araştırma sürecindeki yardımlarından dolayı hocam Sayın Doç. Dr. Saffet ERDOĞAN'a ve doktora çalışmamdaki tüm desteklerinden dolayı ağabeyim ve hocam Sayın Doç. Dr. İbrahim YILMAZ (Afyon Kocatepe Üniversitesi)'a teşekkür ederim.

Doktora çalışmam boyunca bana sabır ve destek gösteren, onları ihmal etmeme hoşgörü ile katlanan değerli eşim Sümeyra'ya ve yaşam sevincimiz, oğlumuz Furkan Berke'ye, yapmış olduğum bu tez çalışmasını ithaf ederim.

Mustafa YILMAZ

AFYONKARAHİSAR, 2012

İÇİNDEKİLER DİZİNİ

	Sayfa
ÖZET	i
ABSTRACT	iii
TEŞEKKÜR	v
İÇİNDEKİLER DİZİNİ.....	vi
SİMGELER ve KISALTMALAR DİZİNİ	viii
ŞEKİLLER DİZİNİ.....	ix
1. GİRİŞ	1
2. YAPAY SİNİR AĞLARI.....	7
2.1 Yapay Zeka	7
2.2 Yapay Sinir Ağları	7
2.2.1 Yapay Sinir Ağlarının Tarihsel Gelişimi	9
2.2.2 Yapay Sinir Ağlarının Üstünlükleri ve Sınırlamaları	11
2.2.3 Yapay Sinir Ağlarının Kullanım Alanları.....	14
2.2.3.1 Yapay Sinir Ağlarının Harita Mühendisliği Alanındaki Uygulamaları	15
2.2.4 Yapay Sinir Ağları ve İstatistik	15
2.2.5 Yapay Sinir Ağlarının Temel Yapı Elemanı.....	17
2.2.5.1 Biyolojik Nöron	17
2.2.5.2 Yapay Nöron.....	18
2.2.6 Yapay Sinir Ağlarının Yapısı	21
2.2.7 Yapay Sinir Ağlarının Sınıflandırılması	23
2.2.7.1 Bağlantı Yapılarına Göre Yapay Sinir Ağları.....	23
2.2.7.1.1 İleri Beslemeli Yapay Sinir Ağları	23
2.2.7.1.2 Geri Beslemeli Yapay Sinir Ağları	24
2.2.7.2 Öğrenme Algoritmalarına Göre Yapay Sinir Ağları.....	25
2.2.7.2.1 Danışmanlı Öğrenme	25
2.2.7.2.2 Danışmansız Öğrenme	26
2.2.7.2.2 Takviyeli Öğrenme	27
2.2.8 Yapay Sinir Ağlarında Temel Öğrenme Kuralları.....	28
3. JEODEZİK NOKTA HIZ KESTİRİMİNDE KULLANILAN YÖNTEMLER	29
3.1 Yapay Sinir Ağı Yöntemleri	29
3.1.1 Geri Yayılımlı Yapay Sinir Ağı.....	29
3.1.1.1 Geri Yayılım Algoritması	30

3.1.2 Radyal Bazlı Fonksiyon Sinir Ağı	38
3.1.3 GYYSA ile RBFSA'nın Karşılaştırılması	40
3.2 Kriging Enterpolasyon Yöntemi	41
4. JEODEZİK NOKTA HIZ KESTİRİM METODOLOJİSİ.....	46
4.1 Uygulamanın Amacı	46
4.2 Çalışma Alanı ve Veri Seti	46
4.3 Uygulama Metodolojisi	47
5. UYGULAMA ve BULGULAR.....	57
6. SONUÇ ve ÖNERİLER.....	75
7. KAYNAKLAR.....	77
ÖZGEÇMİŞ.....	89

SİMGELER ve KISALTMALAR DİZİNİ

Simgeler

f	Aktivasyon fonksiyonu
w	Bağlantı ağırlığı
λ	Boylam
y	Çıktı değeri
φ	Enlem
b	Eşik değeri
ε	Fark (hata)
x	Girdi değeri
$\Delta V_{x,y,z}$	Hız farkı
y'	İstenilen çıktı değeri
α	Momentum katsayısı
$\Delta V_{x,y,z}$	Nokta hız farkı
η	Öğrenme oranı
T	Toplama fonksiyonu

Kısaltmalar

AGA	Ana GPS ağı
BÖHHBÜY	Büyük Ölçekli Harita ve Harita Bilgileri Üretim Yönetmeliği
ÇKA	Çok katmanlı algılayıcı
GYYSA	Geri yayımlı yapay sinir ağı
GPS	Global Konum Belirleme Sistemi (Global Positioning System)
HGK	Harita Genel Komutanlığı
HKO	Hata kareleri ortalaması
KOH	Karesel ortalama hata
KRIG	Kriging
V_x, V_y, V_z	Nokta hız değerleri (Nokta hız vektörü)
RBFSA	Radyal bazlı fonksiyon sinir ağı
SGA	Sıklaştırma GPS ağı
ADALINE	Uyarlamalı Doğrusal Nöron (Adaptive Linear Neuron)
TUTGA	Türkiye Ulusal Temel GPS Ağı
TUYKA	Türkiye Ulusal Yatay Kontrol Ağı
ITRF	Uluslararası Yersel Referans Sistemi (International Terrestrial Reference Frame)
X, Y, Z	Üç boyutlu koordinatlar (Kartezyen koordinatlar)
YSA	Yapay sinir ağları

ŞEKİLLER DİZİNİ

	Sayfa
Şekil 1.1 TUTGA noktalarının coğrafi dağılımı	2
Şekil 1.2 Türkiye ve çevresinin genel tektonik yapısı	3
Şekil 2.1 Biyolojik nöronun yapısı ve bağlantısı	18
Şekil 2.2 Yapay nöronun bileşenleri	19
Şekil 2.3 Aktivasyon fonksiyonlarının grafikleri	21
Şekil 2.4 Çok katmanlı yapay sinir ağlarının genel yapısı	22
Şekil 2.5 Tek katmanlı yapay sinir ağları	22
Şekil 2.6 İleri beslemeli yapay sinir ağları	24
Şekil 2.7 Geri beslemeli yapay sinir ağları	25
Şekil 2.8 Danışmanlı öğrenme yapısı	26
Şekil 2.9 Danışmansız öğrenme yapısı	27
Şekil 2.10 Takviyeli öğrenme yapısı	27
Şekil 3.1 Geri yayımlı yapay sinir ağı	30
Şekil 3.2 Gizli katmandaki nöron sayısına göre eğitim ve test setlerinin hata eğrileri .	35
Şekil 3.3 Öğrenme sürecini sonlandırma aralığı	37
Şekil 3.4 Geri yayılım algoritması için akış diyagramı	38
Şekil 3.5 Radyal bazlı fonksiyon sinir ağı	39
Şekil 4.1 Çalışma alanı ve jeodezik noktaların coğrafi dağılımı	46
Şekil 4.2 1 no'lu jeodezik ağ modeli	48
Şekil 4.3 2 no'lu jeodezik ağ modeli	48

Şekil 4.4 3 no'lu jeodezik ağ modeli	49
Şekil 4.5 4 no'lu jeodezik ağ modeli	49
Şekil 4.6 5 no'lu jeodezik ağ modeli	49
Şekil 4.7 Model - 1 referans hız alanı	51
Şekil 4.8 Model - 2 referans hız alanı	52
Şekil 4.9 Model - 3 referans hız alanı	53
Şekil 4.10 Model - 4 referans hız alanı	54
Şekil 4.11 Model - 5 referans hız alanı	55
Şekil 5.1 Model - 1 V_X hız farkları	58
Şekil 5.2 Model - 1 V_Y hız farkları	59
Şekil 5.3 Model - 1 V_Z hız farkları	60
Şekil 5.4 Model - 2 V_X hız farkları	61
Şekil 5.5 Model - 2 V_Y hız farkları	62
Şekil 5.6 Model - 2 V_Z hız farkları	63
Şekil 5.7 Model - 3 V_X hız farkları	64
Şekil 5.8 Model - 3 V_Y hız farkları	65
Şekil 5.9 Model - 3 V_Z hız farkları	66
Şekil 5.10 Model - 4 V_X hız farkları	67
Şekil 5.11 Model - 4 V_Y hız farkları	68
Şekil 5.12 Model - 4 V_Z hız farkları	69
Şekil 5.13 Model - 5 V_X hız farkları	70
Şekil 5.14 Model - 5 V_Y hız farkları	71

Şekil 5.15 Model - 5 V_z hız farkları	72
Şekil 5.16 Hesaplanan hız farklarının KOH değerleri	73

ÇİZELGELER DİZİNİ

	Sayfa
Çizelge 2.1 YSA ve istatistik terminolojisi arasındaki ilişki.....	16
Çizelge 2.2 Aktivasyon fonksiyonlarının matematiksel yapıları	20
Çizelge 4.1 Uygulama kapsamındaki jeodezik nokta hızlarının istatistiksel değerleri .	47
Çizelge 4.2 Oluşturulan jeodezik ağ modelleri	47
Çizelge 5.1 Hesaplanan hız farklarının istatistiksel değerleri	74

1. GİRİŞ

Jeodezinin tanımı; Helmert (1880)'e göre, yeryüzünün ölçülmesi ve haritaya aktarılması bilimidir. Helmert'in bu klasik tanımı, günümüzde de jeodezinin temelini oluşturmakla birlikte uydu konumlama sistemlerinde, son 30 yılda gerçekleşen teknolojik gelişmeler, jeodezi tanımının genişletilmesini zorunlu kılmıştır. Buna göre, jeodezinin temel problemi, yeryüzünün ve diğer gök cisimlerinin şeklini ve gravite alanını zamanın bir fonksiyonu olarak belirlemektir (Torge 2001). Bu kapsamda jeodezi, üç boyutlu uzayda, yeryuvarının ve diğer gök cisimlerinin;

- Geometrik şeklinin modellenmesi
- Gravite alanının belirlenmesi
- Geometrik şekil ve gravite alanındaki zamana bağlı değişimlerin ölçülmesi

şeklinde üç temel konu üzerinde faaliyetlerini sürdürmektedir (Üstün 2006). Konum ve nitelik bakımından değiştiği bilinen ve değişimleri izlenmek istenen her olay ya da nesne için zamanın kaydedilmesi gerektiğinden jeodezinin üç boyutlu koordinat sisteminde konum belirleme görevi, zamanın tanımlanmasıyla birlikte dördüncü boyuta taşınmış ve uydu konumlama teknikleri kullanılarak zamana bağlı konumsal değişimlerin izlenmesi üzerine daha çok yoğunlaşmıştır.


Global Konum Belirleme Sistemi (GPS), uygun donanıma sahip kullanıcılarına, herhangi bir zamanda, yeryuvarının her yerinde ve tüm meteorolojik koşullar altında konum, yön, zaman ve hız bilgisi sağlamaktadır. GPS ölçmeleri; jeodezik uygulamalar, büyük ölçekli harita üretimi ve coğrafi bilgi sistemi işlemlerinin temeli olan üç boyutlu koordinatların tespit edilmesinde yaygın bir şekilde kullanılmakta olup bilimsel ve teknolojik gelişmelere paralel olarak artan GPS kullanımı, tüm Dünya'da olduğu gibi Türkiye'de de köklü değişimlere neden olmuştur (Güllü et al. 2011a).

Harita Genel Komutanlığı (HGK) tarafından, 1934 ve 1954 yılları arasında, klasik yersel yöntemlerle, Türkiye'nin tektonik yapısı dikkate alınmadan kurulan Türkiye Ulusal Yatay Kontrol Ağı (TUYKA)'nın, yüzey kabuk hareketleri ve meydana gelen depremlerin sebep olduğu deformasyonlar nedeniyle, güncel jeodezik uygulamalar ve

özellikle GPS ölçmeleri için uygun olmaması, yeni bir ulusal jeodezik ağ ihtiyacını doğurmuştur.


GPS'in üç boyutlu konum belirleme olanağını ülke genelinde etkin bir şekilde kullanmak ve ülkemizdeki tektonik plaka hareketleri ile depremler sonucu oluşan konum değişiklikleri nedeniyle güncel jeodezik gereksinimleri büyük ölçüde karşılayamayan TUYKA yerine kullanılmak amacıyla, HGK tarafından 1997 ve 1999 yılları arasında yapılan çalışmalarla Türkiye Ulusal Temel GPS Ağı (TUTGA) kurulmuştur. Ancak 1999 ve 2000 yıllarında meydana gelen büyük ölçekli depremler ($M_w=7.5$ İzmit, $M_w=7.2$ Düzce ve $M_w=6.1$ Çerkeş), deprem bölgesinde yer alan TUTGA nokta konumlarında, GPS ve geometrik nivelman ölçü duyarlılığının çok üzerinde değişikliğe neden olmuştur. Özellikle bu depremlerin etkilerini belirlemek amacıyla 2000 ve 2001 yıllarında GPS ve geometrik nivelman ölçüleri yapılarak TUTGA güncellenmiştir (Aktuğ vd. 2011).

TUTGA, Uluslararası Yersel Referans Sistemi (ITRF) koordinat sisteminde tanımlanmış, nokta konum duyarlılığı 1-3 cm seviyesinde, belirli bir referans epokunda üç boyutlu (kartezyen) koordinatları (X, Y, Z) ve bu koordinatların zamana bağlı değişimleri (hızları; V_x , V_y , V_z) ile uygun sistemde yüksekliği ve jeoid yüksekliği bilinen, nokta aralığı 25-50 km, jeoidin hızlı değişim gösterdiği bölgelerde 15 km olan, olabildiğince homojen dağılımlı 594 noktadan oluşan bir ağıdır (Ayhan vd. 2002). TUTGA noktalarının dağılımı Şekil 1.1'de görülmektedir.



Şekil 1.1 TUTGA noktalarının coğrafi dağılımı (Ayhan vd. 2002).

Türkiye; Alp-Himalaya deprem kuşağında ve Afrika, Arap tektonik plakalarının Avrasya tektonik plakası ile çarpışma bölgesi içinde yer almaktadır (McClusky et al. 2000). Türkiye ve çevresinin Şekil 1.2’de verilen aktif tektonik yapısının neden olduğu deformasyonların büyüklüğü göz önüne alındığında, dört boyutlu (X, Y, Z ve zaman) olarak tasarlanan TUTGA’nın yaşatılması ve iyileştirilmesi için bünyesinde bulunan noktaların zamana bağlı koordinat değişimlerinin yüksek doğrulukla belirlenmesi büyük önem taşımaktadır. Nokta koordinatlarındaki zamana bağlı değişimler, genel olarak tektonik plaka hareketlerinden kaynaklanan deprem öncesi (inter-sismik), deprem anı (ko-sismik) ve deprem sonrası (post-sismik) etkilerdir (Demir ve Açıkgöz 2000). Zamana bağlı bu etkilerin belirlenebilmesi için nokta hızlarının yüksek doğrulukla tespit edilmesi gerekmektedir. TUTGA’nın yaşatılması ve iyileştirilmesi kapsamında periyodik olarak GPS kampanyaları gerçekleştirilmekte ve söz konusu GPS kampanyalarının değerlendirilerek belirlenmiş bir referans epokunda birleştirilmesi sonucu, ITRF sisteminde TUTGA koordinat ve hız alanı hesaplanmaktadır (Aktuğ vd. 2011). TUTGA noktalarına ait hızlar iki veya daha fazla tekrarlı GPS ölçmelerinden veya tekrarlı GPS ölçümü bulunmayan noktalarda diğer TUTGA noktalarının hızlarından kestirilerek hesap edilmektedir (Kurt ve Deniz 2010).



Şekil 1.2 Türkiye ve çevresinin genel tektonik yapısı (Ayhan vd. 2002).

TUTGA nokta hızlarının bir diğer kullanım alanı da jeodezik veya büyük ölçekli harita yapım çalışmaları kapsamındaki ağ sıklaştırma faaliyetleridir. TUTGA'nın kurulmasına müteakip jeodezik uygulamalarda ve büyük ölçekli harita faaliyetlerinde GPS kullanımının artmasına paralel olarak, 2005 yılında Büyük Ölçekli Harita ve Harita Bilgileri Üretim Yönetmeliği (BÖHHBÜY), Resmi Gazete'de yayımlanarak yürürlüğe girmiştir. BÖHHBÜY jeodezik ağ yönetimini yani noktaların koordinatları ile birlikte hızlarının da hesaplanarak kullanılmasını benimsemiştir. Büyük ölçekli harita üretimine yönelik olarak, uydu konumlama teknikleriyle TUTGA'nın sıklaştırılması amacıyla oluşturulan C1 dereceli Ana GPS Ağı (AGA) ve C2 dereceli Sıklaştırma GPS Ağı (SGA) kapsamında tesis edilen noktaların ölçme epokundaki koordinatları, değerlendirmelerde zaman birliği sağlamak amacıyla, belirlenmiş bir referans epokuna ötelenirler. Bu işlem için kullanılacak olan AGA ve SGA nokta hızları, TUTGA nokta hızlarından enterpolasyonla hesaplanır (HKMO 2008).

Jeodezik ağların yaşatılması ve iyileştirilmesi amacıyla farklı zamanlarda gerçekleştirilen GPS kampanyalarının aynı referans epokunda birleştirilerek değerlendirilmesi ile belirlenen jeodezik ağ hız alanı modelinde; tektonik uyumsuzluk veya tekrarlı GPS ölçümü sayısındaki yetersizlik nedeniyle hızları iyi bir şekilde belirlenememiş noktaların hızları ile jeodezik ağ sıklaştırmaları kapsamında tesis edilen noktaların hızları, ağda mevcut olup hızları bilinen noktalar yardımıyla kestirilmektedir. Jeodezik ağların hız alanlarının hesaplanmasının yanı sıra GPS ile yüzey kabuğu hareketlerinin, fay sistemlerinin ve tektonik hareketlere bağlı deformasyonun modellenmesi çalışmalarında da temel parametre olarak kullanılan jeodezik nokta hız bilgilerinin yüksek doğrulukla kestirilmesi büyük önem arz etmektedir.

Jeodezik ağ hız alanının modellenmesi; Demir ve Açıkgoz (2000), Aktuğ (2003), Nocquet ve Calais (2003), D'Anastasio vd. (2006), Novotny ve Kostecky (2008), Baysal vd. (2010), Kurt ve Deniz (2010), Aktuğ vd. (2011) vb. bilimsel çalışmalarda konu edilmiştir. GPS ölçmeleri kullanılarak yüzey kabuğu hareketlerinin, fay sistemlerinin ve tektonik hareketlere bağlı deformasyonun modellenmesi kapsamındaki hız hesabı uygulamaları arasında; Delacou vd. (2008), Deniz ve Özener (2008), Erdoğan vd. (2009), Hackl vd. (2009), Wright ve Wang (2010) yer almaktadır.

Temeli insan beyninin veri işleme ve karar verme mekanizmasının taklit edilmesine dayanan Yapay Sinir Ağları (YSA), geçtiğimiz yüzyılın son çeyreğinden itibaren, gelişen bilgisayar sistemlerine paralel olarak, birçok bilim ve mühendislik alanında modelleme, sınıflandırma, tahmin ve doğrusal olmayan regresyon gibi çalışmaların yanı sıra kestirim problemleri gibi çok sayıda örnek verinin birlikte değerlendirilmesini gerektiren uygulamalarda da yaygın olarak kullanılmaya başlanmıştır. Yeterli olandan fazla ölçüyü temel ilke kabul eden jeodezide; özellikle son 15 yılda, lokal jeoid tespiti (Kavzoğlu and Saka 2005, Veronez et al. 2006, Lin 2007, Güllü et al. 2011b), yeryuvarı dönüklük parametrelerinin kestirimi (Schuh 2002, Akyılmaz 2005, Liao et al. 2012), jeodezik deformasyon analizi (Miima 2002, Miima and Niemeier 2004, Heine 2008, Neuner, 2010), datum transformasyonu (Tierra et al. 2008, Güllü et al. 2011c), koordinat dönüşümü (Barsi 2001, Lin and Wang, 2006, Yılmaz ve Güllü, 2011), uyşumsuz ölçü testi (Güllü and Yılmaz 2010), jeomanyetik modellere manyetik deklinasyon verisi sağlama (Yılmaz et al. 2010) gibi kapsamlı ölçü kümeleri ile çalışılan problemlerde, YSA uygulamaları gerçekleştirilmiştir.

Hız alanının modellenmesi kapsamında; jeofiziksel uygulamalara yönelik olarak, Calderon-Macias vd. (1998, 2000) sismik dalga verisinden hız hesabı ve analizinde, Baronian vd. (2007, 2009) sentetik sismik veriden hız alanının modellenmesi ve analizinde, Ornthammarath vd. (2008) yeraltı tünellerinin tasarımı aşamasında sismik yüzey hızlarının hesaplanmasında, Riedel ve Heinert (2008) heyelan bölgesindeki hız alanı enterpolasyonunda, Moghtased-Azar ve Zaletnyik (2009) yüzey kabuğu hız alanının modellenmesinde YSA'yı kullanmışlardır. Jeodezik nokta hızlarına yönelik olarak ise Güllü vd. (2011a), 12 adet TUTGA noktası ile oluşturulan lokal bir ağda YSA ile hesaplanan hızları enterpolasyon yöntemleri ile hesaplanmış hızlarla karşılaştırmıştır.

Jeofiziksel çalışmalar bünyesinde yüzey kabuğuna ilişkin hız alanının modellenmesi ile ilgili bazı uygulamalarda YSA kullanılmış olmakla birlikte jeodezik faaliyetlere yönelik olarak; bölgesel bir kontrol ağı bünyesinde nokta hızlarının kestirimi ile ilgili bir YSA uygulamasının bulunmaması, bu çalışmanın çıkış noktasını teşkil etmiştir. Çalışma kapsamında Türkiye'nin orta ve batı Anadolu bölümlerinde yer alan toplam 125 adet

TUTGA noktası seçilerek oluşturulan jeodezik ağlarda, nokta hızlarının kestiriminde YSA'nın kullanılabilirliği araştırılmıştır. Nokta yoğunluğunun sonuçlara olan etkisini değerlendirebilmek amacıyla söz konusu 125 adet nokta ile beş farklı jeodezik ağ oluşturularak, YSA'nın en çok kullanılan iki modeli olan Geri Yayılımlı Yapay Sinir Ağı (GYRSA) (Rumelhart et al. 1986) ve Radyal Bazlı Fonksiyon Sinir Ağı (RBFSA) (Broomhead and Lowe 1988) ile jeodezik nokta hızları hesaplanmıştır. GYRSA ve RBFSA'nın performansını değerlendirebilmek amacıyla HGK tarafından TUTGA hız alanının belirlenmesinde kullanılan Kriging (KRIG) (Aktuğ vd. 2011) enterpolasyon yöntemi ile de hız kestirimi yapılarak elde edilen sonuçlar, karesel ortalama hata (KOH) ölçütüne göre, HGK tarafından belirlenmiş TUTGA noktalarına ait hız değerleri temel alınarak karşılaştırılmıştır.

Gerçekleştirilen bu çalışmanın yapısı şu şekilde özetlenebilir. İkinci bölümde; YSA teorisi, YSA yapıları, YSA çeşitleri, YSA kullanımının avantaj ve dezavantajları şeklinde temel bilgiler verilmiştir. Genel olarak kullanılan YSA yapı, algoritma ve teknikleri ele alınarak daha sonra çalışma kapsamında kullanılacak olan YSA modellerinin alt yapısı oluşturulmuştur. Üçüncü bölümde ise jeodezik nokta hızlarının kestiriminde kullanılan GYRSA ve RBFSA modelleri ile YSA performansını değerlendirme amaçlı olarak kullanılan KRIG enterpolasyon yöntemi hakkındaki temel teori ve kavramlar ile ilgili bilgi verilmiştir. Dördüncü bölümde; çalışmanın özünü oluşturan, farklı YSA modelleri ile jeodezik nokta hız kestirimi probleminde kullanılan veri seti, oluşturulan jeodezik ağlar ve elde edilen sonuçların birbiri karşılaştırılarak değerlendirilmesinde izlenen metodoloji ve işlem adımları ele alınmıştır. Beşinci bölümde; gerçekleştirilen uygulama sonucu hesaplanan nokta hız farkları haritalandırılmış ve istatistiksel açıdan değerlendirilerek özetlenmiştir. Son bölümde ise çalışma kapsamında elde edilen sonuçların tamamı birlikte değerlendirilmiş ve jeodezik nokta hızlarının kestiriminde GYRSA ve RBFSA modellerinin eksik veya yetersiz kaldığı yönler de dikkate alınarak, YSA'nın hız kestirimi probleminde kullanılabilirliği konusunda tespit ve önerilerde bulunularak gelecekteki uygulamalar için bir bakış açısı oluşturulmaya çalışılmıştır.

2. YAPAY SİNİR AĞLARI

2.1 Yapay Zeka

Dünyanın en karmaşık yapısına sahip olan insan beyni, sayısal bir işlemi yapabilmek veya bir problemi çözebilmek için bazen saatlerce uğraşmak zorunda kalmasına karşın deneyimler ile öğrenmiş olduğu bir bilgiyi, karşılaştığı yeni olaylara çok kısa bir sürede uyarlayabilmektedir. Teknolojik gelişmelerin çok önemli boyutlara ulaştığı bilgisayar sistemleri ise karmaşık sayısal işlemleri çok kısa bir sürede gerçekleştirmesine rağmen deneyim yolu ile bilgi edinme ve bu bilgiyi kullanabilme noktasında yetersiz kalmaktadır. Bu noktadan hareketle; bilim adamları, insan beyninin bilgileri nasıl tanımladığı, ne şekilde kullandığı ve nasıl sonuç çıkardığı üzerine çalışmalar yaparak, yapay zeka adı verilen bir sistem oluşturmaya çalışmışlardır.

Yapay zeka sistemi; yapılacak olan eyleme yönelik bir göreve yani bir fiile göre programlanmış bir bilgisayara düşünme yeteneği sağlama girişimidir. Daha geniş bir ifade ile yapay zeka; bir bilgisayarın, insan beynine özgü olan akıl yürütme, anlam çıkartma, yorumlama, genelleme, geçmiş deneyimlerden öğrenme, algılama gibi fonksiyonları gerçekleştirebilme yeteneğidir. Yapay zeka teknikleri;

- Uzman sistemler (expert systems)
- Bulanık mantık (fuzzy logic)
- Genetik algoritma (genetic algorithm)
- Yapay sinir ağları (artificial neural networks)

şeklinde dört grupta toplanmaktadır (Elmas 2003). Yapay zeka ile ilgili araştırmalar, paralel çalışabilmesinden dolayı bilgileri hızlı bir şekilde işleyebilmesi ve donanımının daha kolay gerçekleştirilebilir olması nedeniyle YSA üzerinde yoğunlaşmıştır (Bayraktar 2009).

2.2 Yapay Sinir Ağları

YSA, yapay zeka tekniklerinden öğrenebilen sistemlerin temelini oluşturmaktadır. YSA, insan beyninin temel işlem elemanı olan sinir hücrelerini yani nöronu (neuron)

fonksiyonel olarak taklit ederek biyolojik sinir sisteminin basit bir simülasyonunu oluşturan matematiksel bir bilgi işleme modeli olarak tanımlanabilir. Yapısı, bilgi işleme yöntemlerindeki farklılık ve uygulama alanları nedeniyle YSA'nın birçok bilim dalının kapsamına girmesi nedeniyle, üzerinde fikir birliği sağlanmış tek bir YSA tanımı yoktur. Bazı araştırmacılar, YSA için genel bir tanımlama yapmaktansa YSA türlerinin kendi içinde tanımlanması gerektiğini savunmaktadır. Bununla birlikte, bazı genel tanımlamalar aşağıda verilmektedir:

- YSA, birçok nörondan meydana gelen biyolojik sinir sistemlerin, matematiksel modelidir (Lippmann 1987).
- YSA, paralel yapıda çalışan çok sayıda basit işlemci elemandan oluşan, fonksiyonelliğini ağı yapısıyla ve işlemci elemanlarındaki bağlantıların etkinliğiyle gerçekleştiren bir sistemdir (DARPA 1988).
- YSA, deneysel bilgiyi alan, depolayan ve kullanan fiziksel hücreli sistemlerdir (Zurada 1992).
- YSA, biyolojik sinir sistemlerinin temel performans özelliklerine sahip, bilgi işleme sistemidir (Fausett 1999).
- YSA, deneyimsel bilgileri depolamaya yönelik doğal bir eğilimi olan, basit işlemci birimlerden oluşan, paralel dağıtılmış bir işlemcidir. Bu işlemci iki şekilde beyin ile benzerlik göstermektedir: Bilgi, ağ tarafından bir öğrenme süreciyle çevreden elde edilir. Elde edilen bilgileri biriktirmek için sinaptik (synaptic) ağırlıklar olarak bilinen, nöronlar arası bağlantı güçleri kullanılır (Haykin 1999).
- YSA, insan beyninin özelliklerinden olan öğrenme yolu ile yeni bilgiler türetebilme, yeni bilgiler oluşturabilme ve keşfedebilme gibi yetenekleri herhangi bir yardım almadan otomatik olarak gerçekleştirmek amacı ile geliştirilen bilgisayar sistemleridir (Öztemel 2006).

Gerçek hayatta karşılaşılan ve klasik yöntemlerle çözülemeyen veya çözümü oldukça karmaşık olan problemlere alternatif bir yaklaşım öneren YSA, geçtiğimiz yüzyılın son çeyreğinden itibaren, özellikle bilgisayar teknolojisindeki gelişmelere paralel olarak birçok bilim ve mühendislik alanında, geniş bir uygulama alanı bulmuştur.

2.2.1 Yapay Sinir Ağlarının Tarihsel Gelişimi

YSA ile ilgili çalışmaların başlangıcı 1940'lı yılların başlarına dayanmaktadır. 1943 yılında, nörofizikçi McCulloch ile matematikçi Pitts tarafından, tek bir yapay nöronun aritmetik ve mantıksal işlemler yapmasını sağlayan temel parametrik nonlinear işlem modeli geliştirilmiştir (McCulloch and Pitts 1943). Daha sonra Hebb tarafından, nöronlar arasındaki bağlantı ağırlıklarının ayarlanması amacıyla, YSA'daki öğrenme kavramının temellerini atan ve günümüzdeki birçok öğrenme kuralının temelini oluşturan "Hebb kuralı" geliştirilmiştir (Hebb 1949).

1957 yılında Rosenblatt, YSA uygulamalarında devrim niteliğinde olan, çok katmanlı algılayıcıların temelini oluşturan algılayıcı modeli (perceptron) geliştirmiştir (Rosenblatt 1958). Widrow ve Hoff 1959 yılında, bu algılayıcı model ile aynı niteliklerde fakat daha gelişmiş bir öğrenme algoritmasına sahip, ADALINE (Uyarlamalı Doğrusal Nöron – Adaptive Linear Neuron) adı verilen tekli algılayıcı modelini geliştirmiştir (Widrow and Hoff 1960). Gerçekleşen çıkış değeri ile istenen çıkış değeri arasındaki farka eşit bir hata terimi vasıtasıyla bağlantı ağırlıklarının değiştirildiği bir öğrenme algoritması kullanan ADALINE, mühendislik uygulamalarında kullanılan YSA'lar için, başlangıç olarak kabul edilmektedir.

1969 yılında, Minsky ve Papert, algılayıcı modelin analizini yaparak tek katmanlı algılayıcı modelin doğrusal olmayan fonksiyonlar için kullanılamayacağını ortaya koymuştur (Minsky and Papert 1969). Bu nedenle, YSA üzerinde yapılan araştırmalar, ilgi ve finansman kaybından dolayı oldukça yavaşlamıştır. Bu durgunluğa rağmen bazı bilim adamları YSA çalışmalarını devam ettirmiştir. 1972 yılında Kohonen ve Anderson, birbirlerinden bağımsız olarak yürüttükleri çalışmalar sonucu, çağrışımlı bellek gibi davranan YSA modelini geliştirmiştir (Kohonen 1972, Anderson 1972). Werbos (1974), geri yayılım algoritmasının temeli sayılan matematiksel modeli oluşturmuştur. Grossberg (1976), YSA'nın psikolojik mantıksallığını ve uygulama kolaylığını göstermiştir. 1970'li yılların sonuna doğru Fukushima, görsel şekil ve yapıları tanıma amacıyla Neocognitron modelini geliştirmiştir (Fukushima 1980).

1980’li yılların başlarından itibaren, bilgisayar donanımındaki teknolojik gelişmeler sonucu, YSA ile ilgili çalışmalar tekrar hız kazanmıştır. Hopfield (1982) tarafından gerçekleştirilen çalışmalar ile YSA’nın genelleştirilebileceği ve geleneksel yöntemler ile çözümü zor olan problemlere uygulanabileceği gösterilmiş ve böylece modern YSA devri başlamıştır. 1984’de Kohonen, sinirlerin düzenli sıralanışının eşleme özelliği için, danışmansız öğrenme ağları geliştirmiştir. Rumelhart ve McClelland (1986) ile Rumelhart vd. (1986) tarafından, geliştirilen geri yayılım (back propagation) algoritması kullanılarak birden çok katmanlı YSA’ların, tek katmanlı ağların çözemeyeceği problemleri çözebildiği ortaya konulmuş ve XOR (Exclusive OR) problemi, bir geri yayılım ağı ile çözülmüştür. Broomhead ve Lowe (1988), radyal tabanlı fonksiyonlar (radial basis functions) kullanan, çok katmanlı algılayıcıya bir alternatif olan, ileri beslemeli, katmanlı bir YSA yapısı tanımlamış ve filtreleme konusunda başarılı sonuçlar elde etmiştir. Hornik vd. (1989) ise, YSA araştırmaları için kilometre taşı kabul edilebilecek çalışmalarında, YSA’nın girdiler ve çıktılar arasındaki hem doğrusal hem de doğrusal olmayan fonksiyonel ilişki için evrensel yakınsayıcı (universal approximator) olduğunu göstermiştir.

Specth (1990, 1991) tarafından, radyal tabanlı fonksiyon modelinin daha gelişmiş türleri olan, olasılıksal sinir ağları ve genelleştirilmiş regresyon ağları geliştirilmiştir. Her iki YSA tipi de yeterli veri ile düzgün bir fonksiyona yakınsayabilmektedir. Grossberg vd. (1995) tarafından, bugün yapı tanımlama alanında sıkça kullanılan uyarlanabilir yankı teorisi geliştirilmiştir. Hochreiter ve Schmidhuber (1997), YSA için uzun ve kısa dönem hafıza teorisini geliştirmiştir. İnsan hafızası da, uzun ve kısa dönem hafıza olarak iki alt gruba ayrıldığı için bu teori ile YSA’nın insan beynini taklit edebilme yeteneği bir sonraki seviyeye taşınmıştır. Perez-Ortiz vd. (2003), uzun ve kısa dönem hafıza teorisi ile geliştirilmiş bir Kalman filtreleme yöntemi kullanmış ve bu yeni yapının geleneksel YSA yapıları ile çözülemeyen bazı problemleri çözebildiğini göstermiştir. Ayrıca bu yöntemle YSA eğitimi için geçen sürede de önemli seviyede azalma sağlanmıştır.

Yapılan birçok çalışma içerisinde, YSA’ya olan ilginin tekrar artmasını sağlayan en önemli çalışmalar; 1982’deki Hopfield’in makalesi ve 1986’da Rumelhart ve

McClelland tarafından yazılan kitaptır (Haykin 1999). McCulloch ve Pitts'den bu yana YSA çok önemli bir gelişim süreci yaşamıştır ve nöroloji, psikoloji, fizik, matematik, yersel bilimler ve mühendislik alanlarını da kapsayan disiplinler arası bir uygulama alanı haline gelerek gelişimine devam etmektedir.

2.2.2 Yapay Sinir Ağlarının Üstünlükleri ve Sınırlamaları

İnsanlardaki merkezi sinir sisteminin matematiksel modellemesi olan YSA, genel olarak biyolojik sinir sisteminin üstünlüklerine sahip olması nedeniyle, özellikle doğrusal olmayan sistemler için geleneksel yöntemlere göre daha kolay çözüm üretirler. YSA'nın sahip olduğu genel üstünlükleri aşağıdaki şekilde özetlenebilir.

- **Doğrusal olmayan yapı:** Nöronların, aktivasyon fonksiyonlarından kaynaklanan doğrusal olmama özelliği, nöronlardan oluşan YSA'ya da yayılmış durumdadır. Doğrusal olmayan yapısı nedeniyle YSA; herhangi bir sürekli fonksiyona veya bu fonksiyonun türevine yakınsama yeteneğine sahiptir. Bu özelliğiyle evrensel fonksiyon yakınsayıcı (universal function approximator) olarak tanımlanan YSA, doğrusal olmayan işlemlere de uygulanabilmektedir.

- **Öğrenme:** YSA, verilen girdi ve çıktı arasındaki ilişkiyi öğrenebilme ve öğrendiği bilgiyi sinaptik ağırlıklar yardımıyla dağıtık hafızasında tutma yeteneklerine sahiptir. Buradaki dağıtık hafızadan kasıt, YSA'yı oluşturan nöronlar arasındaki bağlantı ağırlıklarının tek tek herhangi bir anlamının bulunmadığı, fakat tüm ağın sinaptik ağırlıklar matrisinin, öğrenilen bilgiyi içerdiğidir. YSA, öğrendiği bilgiyi, tüm sinaptik ağırlıklarına dağıtarak saklamaktadır.

- **Esneklik ve yerel işlem:** YSA, her biri büyük bir problemin farklı parçası ile ilgilenen çok sayıda basit işlemci elemandan oluşması ve bağlantı ağırlıklarının dinamik olması gibi özelliklerinden dolayı esnek bir yapıya sahiptir. Bu esnek yapı sayesinde ağın bir kısmının zarar görmesi, modelde sadece performans düşüklüğü yaratır fakat YSA işlevini tamamen yitirmez. Ayrıca, toplam işlem yükünü paylaşan işlemci elemanlar arasındaki yoğun bağlantılı yapı, sinirsel hesaplamanın temel güç kaynağıdır. Bu yerel işlem yapısı sayesinde, YSA en karmaşık problemlere bile uygulanabilmektedir (Yurtoğlu 2005).

- **Gerçek zamanlı işlem:** YSA, gerçekleştirdiği hesaplamaları paralel olarak yürütülebildiğinden gerçek zamanlı işlem yapabilir. Bu nedenle, hızlı tepki gerektiren problemlerde, YSA klasik sistemlerden çok daha başarılıdır çünkü dağıtık paralel yapıları sayesinde, birim zamanda çok daha fazla veriyi işleyebilmektedir.

- **Genelleme:** YSA, öğrenme yeteneği sayesinde bilinen örnekleri kullanarak daha önce karşılaşılmamış durumlarda genelleme yapabilmekte, bozuk veya kayıp veriler için çözüm üretebilmektedir.

- **Uyarlanabilirlik:** YSA'nın ağırlıkları, uygulanan probleme göre değiştirilebilmekte yani bir problemi çözmek amacıyla eğitilen YSA, problemdeki değişimlere göre tekrar eğitilebilmektedir. Değişimler sürekli yapıda ise, eğitim işlemi gerçek zamanlı yani YSA çalışırken de gerçekleştirilebilir.

- **Kendi ilişkisini oluşturma:** YSA, kendisine sunulan bilgiye göre kendi ilişkilerini oluşturmakta yani bilgiye ilişkin denklem içermemektedir. Bununla birlikte, sistemin içinde ne olduğu tam olarak analiz edilemez. Bu nedenle YSA, verilen bilgilerden ilişkiler ortaya çıkarabilen bir akıllı kara kutu (Yurtoğlu 2005) olarak da tanımlanabilir.

- **Sınırsız sayıda değişken ve parametre:** YSA, sınırsız sayıda değişken ve parametre ile çalışabildiği için mükemmel bir öngörü doğruluğu ile genel çözümler sağlayabilmektedir. YSA, sonsuz sayıda değişkenin her biri gerektiği anda ve gerektiği kadar kullanılacak şekilde eğitilebilmektedir.

- **Karmaşık problemler:** YSA kullanılarak, matematiksel olarak ifade edilemeyecek kadar karmaşık olan problemler çözümlenebilir çünkü YSA, yapısı gereği bir problemi çözmek için, başlangıçta herhangi bir tanımlamaya ihtiyaç duymamakta ve en uygun çözüme yakınsama eğilimi içinde olmaktadır.

- **Donanım ve hız:** YSA, paralel yapısı nedeniyle büyük ölçekli entegre devre teknolojisi ile gerçekleştirilebilmekte ve bu özellik YSA'nın, tanıma ve denetim gibi gerçek zamanlı uygulamalarda, hızlı bilgi işleme yeteneğini artırmaktadır (Sağıroğlu vd. 2003).

- **Analiz ve tasarım kolaylığı:** YSA modellerinin büyük çoğunluğunda, temel işlemci eleman olan nöronun yapısı yaklaşık olarak aynıdır. Bu nedenle, farklı uygulama alanlarında kullanılan YSA'lar benzer öğrenme algoritmalarını ve teorilerini paylaşabilirler.

YSA'nın yukarıda özetlenen birçok üstün özelliğinin yanı sıra, her sistemde olduğu gibi, göz önünde bulundurulması gereken bazı sınırlamaları da mevcuttur. Bunların arasında en önemlisi; YSA'nın eğitilebilmesine ve test edilebilmesine yetecek genişlikte veri setine ihtiyaç duymasındır. Fakat yeterli veri seti genişliği için belirlenmiş kesin bir ölçüt yoktur. Veri setinin genişliğinin belirlenmesi uygulamaya bağlıdır. Diğer bir sınırlama ise, basit modelleme yapılarına rağmen bazı problemlerin uygulamada zor ve karmaşık bir hale gelebilmesidir. Bazı durumlarda, bir yakınsama sağlamak bile imkansız olabilmektedir fakat bu durum uygulama alanına göre genellikle çok karmaşık problemlerde ortaya çıkmaktadır (Yurtoğlu 2005).

Doğru modelleme için uyulacak kesin kuralların bulunmaması nedeniyle değişken seçimlerinin subjektif olarak yapılması veya deneme-yanılma metodunun kullanılması da YSA'nın sınırlamaları arasında yer alır. Çünkü kullanılan modelin yapısının ve oluşturulan çözümün uygun olup olmadığını test etmek zordur. Modelin yapısı doğru olsa bile, YSA ile en uygun çözüm garanti değildir, yalnızca kabul edilebilir çözümler üretilebilmektedir (Öztemel 2006). Birçok YSA modeli, günümüzde istatistiksel olarak yüksek doğruluklarla çalışsa da birçok kullanıcı, problemlerinin tam olarak çözümünü beklemektedir (Anderson and McNeill 1992). Bu şekildeki bir sınırlama, tam sonucun bulunamadığı veya en uygun çözümün çok fazla zaman aldığı problemler için en hızlı ve optimum çözüm üretildiği için, YSA adına bir üstünlük olarak da değerlendirilebilir.

YSA'nın öğreneceği veri setinin ağa gösterilmesi de başlı başına bir sınırlamadır. YSA, sayısal veri haricinde girdi kabul etmez. Bu nedenle sayısal olmayan verilerin sayısal verilere dönüştürülmesi gerekmektedir. Bu ise tamamen kullanıcının becerisine bağlıdır (Öztemel 2006). Günümüzde gerçek dünyadaki birçok probleme, YSA'nın henüz uygulanamamış olmasının en temel nedenlerinden biri, sayısal olmayan verilerin YSA'ya gösterilmesi probleminin hala tam olarak çözülmemiş olmasıdır.

YSA'nın donanım bağımlı olarak çalışması da temel sınırlamalarından bir tanesidir. YSA ile etkin bir analiz yapılabilmesi için çok hızlı çalışan paralel işlemcilerle ihtiyaç duyulmaktadır. Bu ise doğrudan YSA'nın üzerinde çalıştığı sistem donanımına bağlıdır.

Bunların yanı sıra YSA için bir diğer önemli sınırlama da, davranışlarının açıklanamamasıdır. Bir çözüm üretildiği zaman, bu çözümün neden ve nasıl üretildiği konusunda bilgi bulmak mümkün değildir (Öztemel 2006).

2.2.3 Yapay Sinir Ağlarının Kullanım Alanları

YSA'lar genel olarak, doğrusal olmayan, gürültülü, karmaşık, kesin olmayan, eksik, kusurlu, hata olasılığı yüksek verilerinin bulunması durumunda veya problemin çözümü için matematiksel modelin veya algoritmanın bulunmadığı, sadece örneklerin var olduğu durumlarda kullanılmaktadır. YSA, gerçek hayatta karşılaşılan birçok probleme uygulanmakta olup kullanım alanları için bir sınır yoktur fakat sınıflandırma, modelleme, tahmin, kestirim ve kontrol alanlarında ağırlıklı olarak uygulanmaktadır. Günlük hayatta, finansal konulardan mühendislik alanlarına, tıptan uzay bilimlerine kadar, arıza analizi ve tespiti, haberleşme, endüstriyel üretim, otomasyon, kontrol vb. birçok uygulamada YSA genellikle aşağıdaki işlemleri gerçekleştirmektedir:

- Muhtemel fonksiyon kestirimleri
- Sınıflandırma
- Veri ilişkilendirme
- Desen uygunluğu
- Örüntü eşleştirme/tanım
- Kavramlaştırma/kümeleme
- Zaman serisi analizleri
- Sinyal filtreleme
- Veri tahmini
- Veri ilişkilendirme/yorumlama
- Veri sıkıştırma
- Doğrusal olmayan sinyal işleme
- Doğrusal olmayan sistem modelleme
- Vektör sayısallaştırması
- Optimizasyon
- Zeki ve doğrusal olmayan kontrol

2.2.3.1 Yapay Sinir Ağlarının Harita Mühendisliği Alanındaki Uygulamaları

YSA'nın özellikle, doğrusal olmayan, gürültülü ve karmaşık verilerin bulunduğu problemlere kolay uygulanabilir olması ve alternatif çözümler üretmesi, diğer mühendislik alanlarında olduğu gibi Harita Mühendisliği uygulamalarında da araştırmacıların ilgisini çekmiştir. Harita Mühendisliği alanlarından;

- Jeoid tespiti (Güllü vd. 2011b)
- Deformasyon analizi (Neuner 2010)
- Yer dönüklük parametrelerinin kestirimi (Liao et al. 2012)
- Uyuşumsuz ölçülerin tespiti (Güllü and Yılmaz 2010)
- Jeodezik ağlarda hız alanının modellenmesi (Güllü vd. 2011a)
- Datum transformasyonu ve koordinat dönüşümü (Güllü vd. 2011c, Yılmaz ve Güllü 2011)
- GPS tam sayı belirsizliği çözümü (Lei et al. 2010)
- Fotogrametrik veya uzaktan algılama verilerinin yorumlanması (Kavzoğlu 2009)
- Tarihi haritaların konumlandırılması ve ölçeklendirilmesi (Yılmaz and Güllü 2010)
- Sayısal arazi modeli uygulamaları (Bandara et al. 2011)
- Uzaktan algılama görüntülerinin sınıflandırması ve onarımı (Han et al. 2011)
- Coğrafi bilgi sistemi uygulamaları (Junjie et al. 2010)
- Taşınmaz mal değerlemesi (Peterson and Flanagan 2009)

problemlerinde YSA uygulaması ile güncel, etkin ve başarılı sonuçlar elde edilmiştir.

2.2.4 Yapay Sinir Ağları ve İstatistik

YSA modellerinin çoğunun bilinen istatistik tekniklerine benzemesi nedeniyle, YSA ile istatistik arasında önemli bir kesişim kümesi oluşmuştur. YSA terminolojisinde yer alan hatalı veriden öğrenerek genelleştirme kavramı, istatistiksel çıkarsama ile aynı anlamı taşımaktadır. Dolayısıyla genelleştirme yeteneğine sahip YSA modelleri, istatistiğin temel konusu olan veri analizini içermektedir.

YSA, özellikle karmaşık fonksiyonları modellemek için uygundur. Uygulamalardaki amaç, bilinmeyen bir fonksiyondan tatmin edici bir tahmine ulaşabilmek için yeterli derecede karmaşık yapıda bir YSA oluşturmaktır. YSA'nın her bir modeli genel olarak, matematikte bir fonksiyona karşılık gelebileceğinden, girdilere; hiçbir şeyden etkilenmediklerini belirtmek için bağımsız değişkenler, çıktıları; mutlaka girdilere dayandıkları için bağımlı değişkenler ve nöronların arasındaki bağların her birine; bu iki değişkeni birbirine bağlayan matematiksel ifadenin ağırlıkları (sabitleri, parametreleri) olarak bakılabilir (Şen 2004).

YSA, istatistiksel modeller gibi dağılıma yönelik varsayımlara ihtiyaç duymaktadır. İstatistik bu varsayımların sonuçları ve önem derecesi ile de ilgilenirken, YSA, varsayımların bu yönünü gözardı etmektedir. YSA, öğrenme algoritmalarına göre tanımlanırken, istatistiksel yöntemler sonuçlarına göre tanımlanmaktadır. Örneğin, aritmetik ortalama, basit bir geri yayılım ağı ile kolayca hesaplanabilir. Bunun için, aritmetik ortalama formülünün YSA içerisinde kullanılması yeterlidir. Hesaplama şekli ne olursa olsun, çıktı olarak aritmetik ortalama elde edilir. Bu yüzden bir istatistiksel tekniği uygulamak için farklı algoritmalar ve YSA yapıları kullanılabilir.

YSA ile istatistiksel modellerin benzerliği göz önünde bulundurularak YSA ve istatistik terminolojisi arasındaki ilişki, Çizelge 2.1'de verilmektedir (Sarle 1994).

Çizelge 2.1 YSA ve istatistik terminolojisi arasındaki ilişki

YSA	İstatistik
Model	Ağ
Girdi	Bağımsız değişken
Çıktı	Bağımlı değişken
Hata	Artık
Eğitim	Kestirim
Hata fonksiyonu	Kestirim ölçütü
Örnek	Gözlem
Sinaptik ağırlık	Parametre
Fonksiyonel bağlantı	Transformasyon
Kontrollü öğrenme	Regresyon
KontROLSÜZ öğrenme	Veri indirgeme
Genelleştirme	Enterpolasyon/Ekstrapolasyon

YSA ile istatistik arasındaki etkileşim ve benzerlik göz önünde bulundurularak birçok jeodezi uygulamasında olduğu gibi jeodezik nokta hızlarının hesaplanmasında da YSA, kendine uygulama alanı bulabilmektedir.

2.2.5 Yapay Sinir Ağlarının Temel Yapı Elemanı

YSA'nın temel yapı elemanı (birimi) yapay nöronlardır. Yapay nöronlar, gerçek (biyolojik) nöronların bilgi işleme yeteneklerinin modellenmesine yönelik girişimler sonucu oluşturulmuştur. Bu nedenle biyolojik nöronların yapısının ve işleyişinin tanımlanması, yapay nöronlara geçişte, oluşturulan benzerliğin boyutunun ve sınırlarının görülmesi açısından önem taşımaktadır.


2.2.5.1 Biyolojik Nöron

Biyolojik sinir sistemi; merkezinde, sürekli olarak duyu organlarından bilgiyi alan, yorumlayan ve uygun bir karar üreten beynin (merkezi sinir ağı) bulunduğu, beynin kontrolündeki alıcı ve tepki sinirlerinden oluşan bir sistem olarak tanımlanır. Merkezi sinir ağında bilgiler, alıcı ve tepki sinirleri arasında ileri ve geri besleme yönünde değerlendirilerek uygun tepkiler üretilir. Alıcı sinirler çevreden algıladıkları uyarıları (girdi), beyne bilgi ileten elektriksel sinyallere dönüştürür. Tepki sinirleri ise, beynin ürettiği elektriksel sinyalleri uygun tepkilere (çıkı) dönüştürür.

Biyolojik sinir sisteminin temel fonksiyonel birimi, çevreden aldıkları hücresel bilgiyi işleme ve iletme yetenekleriyle donatılmış biyolojik nöronlardır. Şekil 2.1'de görüldüğü gibi, bir biyolojik nöron; soma (soma, cell body), dendrit (dendrite), akson (axon) ve sinaps (synapse) olmak üzere başlıca dört kısımdan oluşur (Arbib 2003).

Soma olarak adlandırılan hücre gövdesi, nöronu denetler ve nöron bünyesinde gerçekleştirilen etkinliklerinin tümünü yönetmekle sorumludur. Soma, gelen sinirsel sinyalleri işleme olarak belli bir eşik değere ulaştığında nöronun kendi elektrik sinyalini oluşturur. Somadan, dendrit ve akson olarak adlandırılan iki uzantı çıkar. Dendritler, somadan dışarı uzanan ağaç dalları biçimindedir. Sinirsel sinyalleri diğer nöronlardan alarak somaya taşırlar. Aksonlar ise, somada üretilen elektriksel sinyali diğer nöronların

dendritlerine taşımakla görevlidir. Aksonun son bölümünde, dal şeklindeki yapıların sonunda, bağlantı terminalleri olarak görev yapan sinapslar, diğer nöronların dendritlerine bağlantı sağlayan kavşak noktalarıdır. İki nöron arasındaki bilgi alışverişi sinapslarda gerçekleşen elektriksel ya da kimyasal etkileşimle mümkün olmaktadır (Arbib 2003).




Şekil 2.1 Biyolojik nöronun yapısı ve bağlantısı (İnt. Kyn.1)

İnsan beyinde yaklaşık 10^{10} (10 milyar) adet nöron bulunmaktadır ve her bir nöron ile yaklaşık 10 000 adet diğer nöron arasında sinyal akışı sağlayan 6×10^{13} (60 trilyon)'dan fazla bağlantı bulunmaktadır (Yeung et al. 2010). İnsan beyni sürekli bir öğrenim süreci içindedir ve bu süreçte nöronlar arasındaki sinaptik bağlantılar ayarlanmakta veya yeni bağlantılar oluşturulmaktadır. Bu etkin ve karmaşık yapıya rağmen biyolojik bir nöronun tepki hızı, günümüz bilgisayar sistemlerine göre oldukça yavaş olmakla birlikte nöronların paralel yapısından dolayı bilginin daha çabuk işlenmesi ve aynı anda birden fazla karar verilmesi nedeniyle insan beyni duyuşal verileri çok daha hızlı bir şekilde değerlendirebilmektedir.

2.2.5.2 Yapay Nöron

YSA'nın çalışmasına esas teşkil eden temel eleman, yapay nöron (nöron) adı verilen bilgi işleme birimidir. YSA, nöronlar arasında bağlantılar kurularak ve katmanlar halinde gruplandırılarak oluşturulur. Geliştirilen nöron modellerinde bazı farklılıklar olmakla birlikte genel özellikleri ile bir nöron; Şekil 2.2'de görüldüğü gibi, girdiler (x_i), ağırlıklar (w_i), eşik değeri (b), toplama fonksiyonu (T), aktivasyon fonksiyonu (f) ve

çıktı (y) olmak üzere altı temel bileşenden meydana gelir.



Şekil 2.2 Yapay nöronun bileşenleri (Kaftan 2010)

- **Girdiler:** Nörona dış dünyadan veya diğer nöronlardan gelen, YSA'nın öğrenmesi istenen bilgilerdir.
- **Ağırlıklar:** Ağırlıklar bir nörona gelen bilginin önemini ve nöron üzerindeki etkisini gösteren bağlantılardır. Girdiler, ağırlık değerleri ile çarpılarak diğer nörona gönderilir. Ağırlık değerinin sıfır olması herhangi bir etki olmadığını, artı veya eksi olması ise etkinin pozitif veya negatif olduğunu gösterir.
- **Eşik değeri:** Nöronun ya da YSA'nın, çıktı değerinin sıfır olmasını engellemek için kullanılan değerdir.
- **Toplama fonksiyonu:** Nörona gelen ağırlıklandırılmış net girdinin hesaplanmasını sağlayan fonksiyondur. Toplama ifadesi, YSA uygulamalarında genelde toplama işleminin yapılmasından kaynaklanmaktadır fakat toplama işleminin kullanılması ile ilgili herhangi bir zorunluluk söz konusu değildir. YSA'nın yapısına göre toplama fonksiyonu olarak, kendi ağırlığı ile çarpılmış girdi değerlerinin; toplamı, ortalaması, en küçüğü, en büyüğü veya mod değeri kullanılabilir. En yaygın kullanım şekli ise ağırlıklı toplamdır (Beale et al. 2010).

$$T = \sum_{i=1}^n x_i w_i + b \quad (2.1)$$

Burada x girdi değerini, w bağlantı ağırlığını, b eşik değeri göstermekte ve n nörona gelen toplam girdi sayısını ifade etmektedir. Bir problem için kullanılacak en uygun toplama fonksiyonunun belirlenmesi amacıyla kullanılan kesin bir yöntem yoktur.

Genellikle deneme-yanılma metodu kullanılmaktadır. YSA'daki nöronların tamamı aynı toplama fonksiyonuna sahip olabilecekleri gibi her bir nöron farklı toplama fonksiyonu da kullanabilir (Öztemel 2006).


- **Aktivasyon fonksiyonu:** YSA'nın, temel hesaplama işleminin yapıldığı bileşenidir. Nörona gelen net girdiye karşılık nöronun üreteceği çıktının hesaplanmasını sağlayan fonksiyondur. Aktivasyon fonksiyonunun görevi, hem çıktıları $[-1, 1]$, $[0, 1]$ gibi belirli değerler arasında tutmak hem de sürekli bir fonksiyon oluşturmaktır. Aktivasyon fonksiyonun sürekli olması türevinin alınması, türevinin alınması da YSA'nın eğitimi aşamasındaki algoritmaları için gereklidir. Aktivasyon fonksiyonun türev karakteristikleri, eğitim aşamasının hızını ve başarısını etkilemektedir.

Girdi ve çıktı değerleri arasındaki yapının lineer olup olmaması, aktivasyon fonksiyonunun seçiminde büyük önem arz etmektedir (Şen 2004). Lineer yapıda bir aktivasyon fonksiyonu kullanan YSA; lineer fonksiyonlardaki çıktı, girdi ile orantılı olduğu için, sadece lineer problemleri çözebilir. Bu durum ilk YSA denemelerinin başarısızlıkla sonuçlanmasının temel nedenidir (Minsky and Papert 1969).

Aktivasyon işlemi için çeşitli fonksiyonlar kullanılabilmekte olup hangi fonksiyonun kullanılacağına ilişkin kesin bir kural bulunmamaktadır (Öztemel 2006). YSA'nın uygulandığı hangi problemlerde hangi tip aktivasyon fonksiyonunun kullanılacağı söz konusu problemin yapısına bağlıdır ve deneme-yanılma metodu ile etkin bir şekilde tespit edilebilir. YSA literatüründe yaygın olarak kullanılan; sigmoid, hiperbolik tanjant, lineer, basamak, Gauss ve multi kuadratik aktivasyon fonksiyonlarının (Graupe 2007, Patan 2008, Beale et al. 2010) matematiksel yapıları Çizelge 2.2'de, grafikleri ise Şekil 2.3'de verilmektedir.

Çizelge 2.2 Aktivasyon fonksiyonlarının matematiksel yapıları

Aktivasyon Fonksiyonu	Matematiksel Yapı
Sigmoid	$f(T) = 1/(1 + e^{-T})$
Hiperbolik tanjant	$f(T) = (e^T + e^{-T})/(e^T - e^{-T})$
Lineer	$f(T) = T$
Basamak	$f(T) = 1 \Rightarrow T \geq 0; -1 \Rightarrow T < 0$
Gauss	$f(T) = e^{-[(T-c)^2/\sigma^2]}$
Multi kuadratik	$f(T) = \sqrt{r^2 + (T - c)^2}/r$



Şekil 2.3 Aktivasyon fonksiyonlarının grafikleri


- **Çıktı:** Aktivasyon fonksiyonu tarafından hesaplanan $y = f(T)$ değeri, nöronun çıktı değeridir. Bazı durumlarda, nöron tarafından bir çıkış fonksiyonu yardımıyla çıktıya ölçeklendirme ve sınırlandırma işlemi uygulanması gerekebilir. YSA'nın yapısına göre, üretilen çıktı değeri başka bir nörona girdi olarak veya bir dış bağlantıya sonuç olarak gönderilebilir.

YSA'ların tamamı, yukarıda temel bileşenleri açıklanan nöronlardan oluşmaktadır. Nöronların tasarımı (toplama ve aktivasyon fonksiyonlarının seçimi) YSA mimarisinin ilk aşamasıdır. İkinci aşama ise nöronların kümelenendirilmesini ve aralarındaki bağlantıların oluşturulmasını içermektedir.

2.2.6 Yapay Sinir Ağlarının Yapısı


YSA'larda, nöronların kümelenendirilme işlemi katmanlar halinde yapılmaktadır ve daha

sonra bu katmanlar birbirleri ile ilişkilendirilmektedir. Temel olarak bir YSA'nın genel yapısı, Şekil 2.4'de gösterilmektedir. Bu yapıda, bazı nöronlar girdileri almak için bazı nöronlar ise çıktıları iletmek için dış mekan ile bağlantı halindedir. Geriye kalan tüm nöronlar ise gizli katmanlarda kümelenmiştir yani, sadece YSA içinde bağlantıları bulunmaktadır.



Şekil 2.4 Çok katmanlı yapay sinir ağlarının genel yapısı

YSA mimarisinde amaç, nöron yığını oluşturmaktan çok nöronları katmanlar halinde gruplandırarak, katmanlar arasındaki bağlantıları oluşturmaktır. Literatürdeki ilk YSA uygulamaları gizli katmanı bulunmayan, sadece girdi ve çıktı katmanlarından oluşan yapılar ile gerçekleştirilmiştir. Girdi katmanındaki nöronların girdi değerleri üzerinde bir işlem uygulamaması, sadece girdileri bir sonraki katmana aktarması nedeniyle, niceliksel olarak girdi katmanı, katman sayısına dahil edilmemektedir. Bu nedenle bu tür yapılar tek katmanlı YSA olarak adlandırılmaktadır (Şekil 2.5).



Şekil 2.5 Tek katmanlı yapay sinir ağları

Güncel uygulamaların çoğu, girdilerin ayrılamaması ve dağılımının belirlenememesi durumunda kararsız kalan tek katmanlı YSA yerine çok katmanlı (girdi katmanı, bir veya birden fazla gizli katman, çıktı katmanı) YSA yapısına (Şekil 2.4) ihtiyaç duymaktadır.

- **Girdi katmanı:** Gelen bilgilerin işlenmeden YSA'ya iletildiği katmandır. Girdi katmanındaki nöron sayısı, YSA'ya sunulan veri sayısına eşittir.
- **Gizli katman:** Girdi katmanından gelen bilgilerin aktivasyon fonksiyonu ile işlenerek çıktı katmanına gönderildiği katmandır. Çok katmanlı YSA yapısında, birden fazla gizli katman oluşturulabilir.
- **Çıktı katmanı:** Gizli katmandan gelen bilgiyi işleyerek dış dünyaya gönderen katmandır.

YSA'nın genel çalışma prensibi; bir girdi setini (örnekleri) alarak, katmanlar halinde kümelenendirilmiş nöronları vasıtasıyla çıktı setine çevirmektir.

2.2.7 Yapay Sinir Ağlarının Sınıflandırılması


YSA'lar; nöronları arasındaki bağlantı yapıları ve veri akış yönüne göre ileri beslemeli (feed-forward) ve geri beslemeli (feed-back veya recurrent) olarak iki grupta, kullandıkları öğrenme algoritmalarına göre danışmanlı (supervised), danışmansız (unsupervised) ve takviyeli (reinforcement) öğrenme olarak üç grupta sınıflandırılmaktadır (Zurada 1992, Blackwell and Chen 2009).

2.2.7.1 Bağlantı Yapılarına Göre Yapay Sinir Ağları

2.2.7.1.1 İleri Beslemeli Yapay Sinir Ağları

İleri beslemeli YSA'da nöronlar, genellikle katmanlar halinde kümelenendirilmiştir ve nöronlar arasındaki iletişim girdi katmanından çıktı katmanına doğru tek yönlü bağlantılarla gerçekleştirilir. Girdi ve çıktı katmanları arasında, doğrusal olmayan yapıda gizli katman bulunur. Nöronlar bir katmandan diğer bir katmana ileri yönlü bağlantı kurarken, aynı katman içerisindeki nöronlar arasında bağlantı söz konusu

değildir. Bu nedenle nöronlar arasındaki bağlantılar bir döngü oluşturmamakta ve ileri beslemeli YSA, girilen verilere karşılık, hızlı bir şekilde çıktı üretebilmektedir. İleri beslemeli YSA'lara örnek olarak, Çok Katmanlı Algılayıcılar (Multilayer Perceptron) ve RBFSA verilebilir (Blackwell and Chen 2009). Şekil 2.6'da genel yapısı verilen, ileri beslemeli YSA, bu yapısı ile girdi ve çıktı uzayları arasında, doğrusal olmayan, statik bir işlevi gerçekleştirir. İleri beslemeli YSA, statik yapıda bir hafızaya sahiptir, diğer bir ifade ile herhangi bir andaki çıktı değeri sadece o andaki girdi değerlerinin bir fonksiyonudur. İleri beslemeli YSA, gizli katmanında yeterli sayıda nöron olmak kaydıyla, herhangi bir sürekli fonksiyonu istenilen doğrulukta yakınsayabilmektedir (Lee and Jeng 1998).




Şekil 2.6 İleri beslemeli yapay sinir ağı

2.2.7.1.2 Geri Beslemeli Yapay Sinir Ağları

Geri beslemeli YSA'da, çıktı katmanındaki veya gizli katmanlardaki nöronların çıkışları, girdi veya önceki gizli katmanlardaki nöronlara tekrar giriş olarak iletilir (Zhang 2004). Böylece veri akışı hem ileri hem de geri yönlü olmaktadır. Geri beslemeli YSA, dinamik yapıda bir hafızaya sahiptir yani bir andaki çıktı hem o andaki hem de önceki girdilerin bir fonksiyonudur. Bu nedenle, özellikle gürültülü sistemlerdeki tahmin ve sınıflandırma işlemleri için uygundur (Beale et al. 2010). Geri beslemeli YSA'da geri besleme, genellikle, bilginin Δt kadarlık zaman geciktirimi ile oluşur. Geri besleme, aynı katmandaki nöronlar arasında olduğu gibi farklı katmanlardaki nöronlar arasında da olabilmektedir. Geri beslemeli YSA'lara örnek

olarak Hopfield, Elman ve Jordan ağırları verilebilir (Nabiyev 2010). Geri beslemeli YSA'nın genel yapısı Şekil 2.7'de verilmektedir.



Şekil 2.7 Geri beslemeli yapay sinir ağı


2.2.7.2 Öğrenme Algoritmalarına Göre Yapay Sinir Ağları

YSA'lar, insan beyni gibi öğrenebilme yeteneğine sahip olmaları nedeniyle, klasik programlama gibi belirli bir algoritma çerçevesinde programlanmazlar. YSA'da bilgi, ağıdaki bağlantıların ağırlıklarında depolanır. Kesin olarak belirlenmiş bir işlevin, YSA tarafından belirli kurallar yardımıyla, verimli bir şekilde gerçekleştirilebilmesi amacıyla, YSA'nın nöronlarını bağlayan ağırlıkların güncellenmesi süreci, YSA'nın öğrenimi ya da eğitimi adını alır. YSA, kendisine sunulan eğitim setindeki verileri kullanarak nöronları bağlayan ağırlık katsayılarını öğrenir. YSA'nın öğrenme performansı, ağırlık katsayılarının güncellenmesi ile artar. Bilginin kurallar şeklinde tanımlandığı klasik uzman sistemlerin tersine YSA, girdi katmanına ve/veya çıktı katmanına gösterilen örneklerden çıkarımlar yaparak, verilere ilişkin kendi kurallarını oluşturur. Bağlantı ağırlıklarının değiştirilmesi işlemi, kullanılan öğrenme algoritmasına göre danışmanlı, danışmansız ve takviyeli öğrenme şeklinde üç grupta ele alınmaktadır.

2.2.7.2.1 Danışmanlı Öğrenme

YSA'ya, bağımsız değişkenleri yani girdi değerlerini ($x_1, x_2, \dots, x_n$) ve bunlara karşılık gelen bağımlı değişkeni yani istenilen çıktı değerini (y') göstererek, YSA tarafından üretilen çıktı (y) ile bağımlı değişken arasındaki farkın yani hatanın (ϵ) minimize

edilmesine dayanan öğrenme algoritmasına, danışmanlı öğrenme adı verilir (MacKay 2004). Söz konusu fark, kullanılan performans ölçütlerine göre kabul edilebilir bir seviyeye ininceye kadar YSA'nın bağlantı ağırlıkları güncellenir. Girdi ve çıktı değerlerinden oluşan eğitim seti, YSA'nın öğrenme sürecinde danışman (öğretmen) görevi görmektedir. Danışmanlı öğrenmede YSA'nın danışmana benzemesi amaçlanır (Haykin 1999). Danışmanlı öğrenmede dikkat edilmesi gereken en önemli nokta; YSA'nın eğitimi için kullanılacak veri setinin, hem öğrenimi hem de genellemeyi sağlayacak biçimde oluşturulmasıdır. YSA'nın eğitim seti dışı dışındaki veriler için doğru sonuç verebilmesi, eğitim setinin hem yeterli hacimde olmasına, hem de örneklemeyi çok iyi biçimde temsil edebilmesine bağlıdır.




Şekil 2.8 Danışmanlı öğrenme yapısı

Şekil 2.8'de yapısı gösterilen danışmanlı öğrenmeye örnek olarak, Widrow ve Hoff (1960) tarafından geliştirilen delta kuralı ve Rumelhart vd. (1986) tarafından geliştirilen genelleştirilmiş delta kuralı (geri yayılım algoritması) verilebilir.

2.2.7.2.2 Danışmansız Öğrenme

Öğrenme sürecinde, YSA'ya, yalnızca bağımsız değişkenlerin yani girdi değerlerinin sunulduğu fakat bunlara karşılık istenilen çıktı değerinin verilmediği öğrenme algoritmasına, danışmansız öğrenme adı verilir (Bishop 2005). Eğitim seti, sadece girdi değerlerinden oluşmaktadır ve YSA'nın üretmiş olduğu çıktı değerini karşılaştırarak kontrol işlevini gerçekleştireceği bir danışman söz konusu değildir. Danışmansız

öğrenmede YSA, istenilen çıktı değeri olmaksızın girdi değerlerinin özelliklerine göre desenler (patterns) oluşturarak bağlantı ağırlıklarını günceller ve her veri kümesi için örnek bir vektör üretir (Fausett 1999).




Şekil 2.9 Danışmansız öğrenme yapısı

Şekil 2.9’da yapısı gösterilen danışmansız öğrenme, danışmanlı öğrenmeye göre daha hızlı ve matematiksel algoritması daha basittir. Danışmansız öğrenmeye örnek olarak, Hebb kuralı (Hebb 1949), Kohonen kuralı (Kohonen 1972) ve Hopfield kuralı (Hopfield 1982) verilebilir.

2.2.7.2.2 Takviyeli Öğrenme

Takviyeli öğrenme, danışmansız öğrenme gibi istenilen çıktı değerinin bilinmesine ihtiyaç duymaz. İstenilen çıktı değerini elde etmek için girdi değerleri ile YSA’nın ürettiği çıktı değerini değerlendiren bir uygunluk derecesi kullanılır (Sutton and Barto 1998). Şekil 2.10’da takviyeli öğrenme yapısı gösterilmektedir. Optimizasyon problemlerini çözmek için geliştirilen Boltzmann kuralı (Hinton and Sejnowski 1986) takviyeli öğrenmeye örnek olarak verilebilir.



Şekil 2.10 Takviyeli öğrenme yapısı

2.2.8 Yapay Sinir Ağlarında Temel Öğrenme Kuralları

YSA'nın öğrenme sürecinde, bağlantı ağırlıklarının neye göre değiştirileceğini belirleyen matematiksel algoritmalara öğrenme kuralı adı verilir. Literatürde YSA eğitimi için geliştirilmiş çok sayıda öğrenme kuralı mevcut olmakla beraber bunların çoğunluğu, temelde Hebb kuralından (Hebb 1949) üretilmiştir. Bu bölümde, temel öğrenme kuralları ele alınmaktadır.

- **Hebb kuralı:** Bu kurala göre; aralarında doğrudan bağlantı bulunan sinyal alıcı ve gönderici nöronlar, eş zamanlı olarak aktive oluyorsa (ikisi de matematiksel olarak aynı işarete sahip ise), bu iki nöron arasındaki bağlantının ağırlığı artırılır. Aksi halde bağlantının ağırlığının azaltılması gerekmektedir.

- **Hopfield kuralı:** Bu kuralda, Hebb kuralına ek olarak, bağlantı ağırlıklarındaki değişimlerin ne kadar olacağı da belirtilmektedir. Bu kurala göre; bağlantı ağırlığı öğrenme oranı (learning rate) kadar artırılır ya da azaltılır. Öğrenme oranı, pozitif ya da negatif bir sayısal değerdir. Uygulamada öğrenme oranı (η), genel olarak sıfır ile bir arasında bir değer olarak seçilmektedir.

- **Delta kuralı:** Bu kurala göre; bağlantı ağırlıkları, istenilen çıktı değeri ile YSA tarafından üretilen çıktı değeri arasındaki fark minimum oluncaya kadar, değiştirilmektedir. Amaç, söz konusu farkın karelerinin toplamının en aza indirgenmesidir. Bu kural, aynı zamanda Widrow-Hoff ve en küçük kareler ortalaması (least mean square) kuralı olarak da bilinir.

- **Kohonen kuralı:** Bu kural, biyolojik sistemlerdeki öğrenme prensibinden esinlenerek geliştirilmiştir. Bu kurala göre; nöronlar öğrenmek için yarışır. En büyük çıkışa sahip nöron kazanır ve bağlantı ağırlıkları güncellenir. Kazanan nöron, komşularını uyarma ve yasaklama özelliğine de sahiptir.

- **Genelleştirilmiş delta kuralı:** Geri yayılım algoritması olarak da bilinen bu kural, en küçük kareler ortalamasına dayanan delta kuralının genelleştirilmiş halidir. Bağlantı ağırlıklarının değiştirilmesi için YSA'da kullanılan aktivasyon fonksiyonunun birinci derece türevi kullanılmaktadır.

3. JEODEZİK NOKTA HIZ KESTİRİMİNDE KULLANILAN YÖNTEMLER

Jeostatistik (Matheron 1963) kapsamında yer alan mekansal kestirim; Cressie (1993) tarafından, mekansal değişkenlerin, çalışma alanında örneklenmemiş bir noktadaki değerinin, örneklenmiş noktalardaki bilinen değerler yardımıyla hesaplanması olarak tanımlanmaktadır. Bu çalışmada, jeodezik ağ bünyesindeki hızları bilinen noktalar yardımıyla diğer noktaların hızlarının hesaplanması problemi, mekansal kestirim kapsamında değerlendirmiş ve jeodezik nokta hız kestirimi için; YSA uygulamalarının en yaygın çok katmanlı algılayıcı (multilayer perceptron) (ÇKA) modeli olan GYYSA, birçok YSA uygulamasında ÇKA'ya alternatif olarak önerilen RBFSA ve en iyi mekansal enterpolasyon yöntemi olarak kabul edilen KRIG kullanılmıştır.

3.1 Yapay Sinir Ağı Yöntemleri


3.1.1 Geri Yayılımlı Yapay Sinir Ağı

GYRSA; katmanları arasında tam bağlantı bulunan, ileri beslemeli ve danışmanlı olarak eğitilen bir ÇKA modelidir. GYRSA, uygulama kolaylığı, esnek yapısı, yüksek öğrenme kapasitesi ve farklı problemlere uyarlanabilir olması nedeniyle günümüzde en yaygın kullanılan YSA modelidir (Haykin 1999, Alavala 2007, Graupe 2007, Beale et al. 2010). GYRSA, bir girdi katmanı, bir veya birden fazla gizli katman ve bir çıktı katmanından oluşmaktadır. Katmanlardaki nöronlar, verilen girdiyi işleyerek diğer nöronlara iletmekte ve istenilen çıktıya ulaşmayı sağlamaktadır. Verilen her bir girdi değeri, her nöronun ilgili ağırlığı ile çarpılarak toplanmakta ve net girdi hesaplanmaktadır. Nöronda hesaplanan net girdi, aktivasyon fonksiyonu kullanılarak çıktıya dönüştürülmektedir. GYRSA'da aktivasyon fonksiyonu olarak, türevinin kolay alınabilir olmasının öğrenim sürecinde hataların geri yayılımını kolaylaştırdığı için, Çizelge 2.2'de ifade edilen sigmoid fonksiyonu, yaygın bir şekilde kullanılmaktadır (Haykin 1999, Beale et al. 2010).

GYRSA'da nöronlar, katmanlar arasındaki bağlantıyı sağlar fakat aynı katmandaki nöronlar arasında bağlantı söz konusu değildir. Bu nedenle, girdi katmanından çıktı

katmanına doğru gerçekleşen veri akışı ileri besleme yapısını oluşturur. Öğrenme sürecinde, GYYSA'nın ürettiği çıktı değeri ile istenilen çıktı değeri arasındaki farkın azaltılması amacıyla, bağlantı ağırlıklarının çıktı katmanından girdi katmanına doğru güncellenmesi de hatanın geri yayılımını oluşturmaktadır (Graupe 2007).

Genel yapısı Şekil 3.1'de verilmekte olan GYYSA, farklı öğrenme kuralları ile eğitilebilmektedir. Özellikle doğrusal olmayan ilişkilerin analizinde uygulamasının pratik olması ve matematiksel olarak kolay ispatlanabilmesi nedeniyle, standart geri yayılım algoritması (genelleştirilmiş delta kuralı) (Rumelhart et al. 1986), GYYSA eğitimi için yaygın olarak kullanılmaktadır (Haykin 1999, Alavala 2007, Beale et al. 2010).



Şekil 3.1 Geri yayımlı yapay sinir ağı

3.1.1.1 Geri Yayılım Algoritması

Geri yayılım algoritması (Rumelhart et al. 1986); YSA tarafından üretilen çıktı değerindeki mevcut hata düzeyine göre, YSA hatasının minimize edilmesi için bağlantı ağırlıklarının adım adım hesaplanması sürecidir (Haykin 1999, Bishop 2005). Geri yayılım algoritmasının uygulanması sürecinde GYYSA, her girdi verisini, çıktı katmanındaki nöronlarda sonuç üretmek üzere, gizli katmandaki nöronlardan geçirir. Daha sonra çıktı katmanındaki hataları bulabilmek için, istenilen çıktı değeri ile elde edilen çıktı değeri karşılaştırılır. Bir sonraki aşamada, çıktı hatalarının türevi, çıktı katmanından geriye doğru, gizli katmana geçirilir. Hata değerleri hesaplandıktan sonra,

nöronlar kendi hatalarını minimize etmek üzere bağlantı ağırlıklarını günceller. Ağırlık güncelleme işlemleri, GYYSA'daki performans fonksiyonunu minimum yapacak şekilde düzenlenir. Geri yayılım algoritmasında, gizli katman sayısı, gizli katmandaki nöron sayısı, aktivasyon fonksiyonu, ağırlıkların GYYSA'ya tanıtılması, öğrenme katsayısı ve momentum, eşik değeri, hata hesaplaması, ağırlıkların güncellenmesi vb. parametreler kullanıcı tarafından kontrol edilebilmektedir (Poulton 2001). Temel olarak geri yayılım algoritmasının işleyişi;

- **İleri besleme:** Girdi katmanından çıktı katmanına doğru veri (sinyal) akışı,
 - **Geri yayılım:** Çıktı katmanından girdi katmanına doğru hatayı minimize edecek biçimde ağırlıkların güncellenmesi,
- olarak iki aşama şeklinde özetlenebilir.

Şekil 3.1'deki gibi tek gizli katmana sahip bir GYYSA için, geri yayılım algoritmasının genel bir formülasyonunu vermek gerekirse:

k. adımda, j. nöronunun çıktısındaki hata sinyali, üretilen çıktı değeri ile istenilen çıktı değeri arasındaki fark olarak tanımlanır:

$$\varepsilon_j(k) = y'_j(k) - y_j(k) \quad (3.1)$$

K, çıktı katmanındaki nöron sayısı olmak üzere, çıktı katmanındaki bütün nöronlar için anlık hata değerinin toplanmasıyla k. adımdaki toplam anlık karesel hata değeri olan $e(k)$ elde edilir:

$$e(k) = \frac{1}{2} \sum_{j=1}^K \varepsilon_j^2(k) \quad (3.2)$$

N, eğitim setindeki toplam girdi sayısı olmak üzere, toplam anlık karesel hata değerine bağlı olarak, hata kareleri ortalaması (HKO) hesaplanır:

$$e_{ort} = \frac{1}{N} \sum_{n=1}^N e(k) \quad (3.3)$$

$e(k)$ ve buna bağlı e_{ort} , GYYSA'nın bütün serbest parametrelerinin (bağlantı ağırlıklarının) bir fonksiyonudur. Bir eğitim seti verildiğinde, e_{ort} , GYYSA'nın öğrenme sürecinin performans ölçüsü olarak kullanılmaktadır. Geri yayılım algoritmasının amacı, hesaplanan HKO'yu minimize etmek için GYYSA'nın serbest parametrelerini güncellemektir. Ağırlıkların güncellenmesi, GYYSA'ya sunulan her bir veri için kendi

hatalarına uygun olarak ayarlanmasıdır (Haykin 1999). n , nörona gelen bağlantı sayısı olmak üzere, j . nöronun ağırlıklandırılmış girdilerinin toplamı (net girdisi) aşağıdaki şekilde tanımlanır:

$$T_j(k) = \sum_{i=0}^n w_{ij}(k) \cdot x_i(k) \quad (3.4)$$

Eşitlik 3.4’de $x_0 = +1$ olarak alınır. Bu durumda w_{0j} ağırlığı, j . nöron için b_j eşik değerine eşit olacaktır. Böylece, f aktivasyon fonksiyonu (sigmoid) kullanılarak, k . adımda j . nöronun çıktı değeri, aşağıdaki şekilde hesaplanır:

$$y_j(k) = f_j(T_j(k)) = \frac{1}{1 + e^{-(T_j(k))}} \quad (3.5)$$

En küçük kareler algoritmasına benzer olarak, geri yayılım algoritmasında da, çıktı katmanında, $\frac{\partial e(k)}{\partial w_{ij}(k)}$ kısmi türeviyle orantılı olan $w_{ij}(k)$ ağırlığı için $\Delta w_{ij}(k)$ düzeltme faktörü uygulanır. Bu kısmi türev, zincir kuralına göre aşağıdaki eşitlik ile elde edilir:

$$\frac{\partial e(k)}{\partial w_{ij}(k)} = \frac{\partial e(k)}{\partial \varepsilon_j(k)} \cdot \frac{\partial \varepsilon_j(k)}{\partial y_j(k)} \cdot \frac{\partial y_j(k)}{\partial T_j(k)} \cdot \frac{\partial T_j(k)}{\partial w_{ij}(k)} \quad (3.6)$$

$\frac{\partial e(k)}{\partial w_{ij}(k)}$ kısmi türevi, w_{ij} ağırlığı için, ağırlık uzayında aramanın yönünü belirleyen bir duyarlılık faktörüdür. Eşitlik 3.2’nin her iki tarafının, $\varepsilon_j(k)$ ’ye göre türevi alınır;

$$\frac{\partial e(k)}{\partial \varepsilon_j(k)} = \varepsilon_j(k) \quad (3.7)$$

elde edilir. Eşitlik 3.1’de her iki tarafın, $y_j(k)$ ’ye göre türevi alınır;

$$\frac{\partial \varepsilon_j(k)}{\partial y_j(k)} = -1 \quad (3.8)$$

elde edilir. Ayrıca Eşitlik 3.5’de her iki tarafın, $T_j(k)$ ’ye göre türevi alınır;

$$\frac{\partial y_j(k)}{\partial T_j(k)} = f'_j(T_j(k)) \quad (3.9)$$

elde edilir. Son olarak Eşitlik 3.4’de her iki tarafın, $w_{ij}(k)$ ’ye göre türevi alınır;

$$\frac{\partial T_j(k)}{\partial w_{ij}(k)} = x_i(k) \quad (3.10)$$

elde edilir. Eşitlik 3.7, 3.8, 3.9 ve 3.10'daki türevler, Eşitlik 3.6'da ifade edilen zincir kuralına uygulanırsa, söz konusu eşitlik;

$$\frac{\partial e(k)}{\partial w_{ij}(k)} = -\varepsilon_j(k) \cdot f'_j(T_j(k)) \cdot x_i(k) \quad (3.11)$$

biçiminde yazılabilir.

k. adımdan (k+1). adıma geçişte bağlantı ağırlıklarının değişim algoritması;

$$w_{ij}(k+1) = w_{ij}(k) + \Delta w_{ij}(k) \quad (3.12)$$

şeklinde ifade edilir. Bu eşitlikte k. adımda j. nöronun girdisi ile bir önceki katmandaki nöronun çıktısını bağlayan ağırlığa uygulanan ağırlık düzeltme faktörü çekildiğinde;

$$\Delta w_{ij}(k) = w_{ij}(k+1) - w_{ij}(k) \quad (3.13)$$

elde edilir. Delta kuralı olarak isimlendirilen bu ifadeden yararlanılarak, her ağırlığa göre ölçülen hatanın türevinin eksi işaretlisiyle orantılı olarak, söz konusu ağırlık ayarlanmaktadır:

$$\Delta w_{ij}(k) = -\eta \frac{\partial e(k)}{\partial w_{ij}(k)} \quad (3.14)$$

Burada η , geri yayılım algoritmasının öğrenme oranı olarak tanımlanan, pozitif bir sayıdır. $\Delta w_{ij}(k)$, ağırlık düzeltmesinin hesaplanmasında kullanılan temel faktör olan j. nöronunun çıktısındaki $\varepsilon_j(k)$ hatasıdır. Yukarıdaki eşitlik, ağırlığı değiştirmek için $e(k)$ 'nin değerini indirgemeyi araştırır. Eşitlik 3.14'de, $\frac{\partial e(k)}{\partial w_{ij}(k)}$ değeri yerine yazılırsa;

$$\Delta w_{ij}(k) = \eta \delta_j(k) x_i(k) \quad (3.15)$$

elde edilir. Buradaki $\delta_j(k)$, k. adımda j. nöronunun üretilen çıktısı ile istenilen çıktısı arasındaki fark olarak tanımlanır ve,

$$\delta_j(k) = -\frac{\partial e(k)}{\partial T_j(k)} = -\frac{\partial e(k)}{\partial \varepsilon_j(k)} \cdot \frac{\partial \varepsilon_j(k)}{\partial y_j(k)} \cdot \frac{\partial y_j(k)}{\partial T_j(k)} = \varepsilon_j(k) \cdot f'_j(T_j(k)) \quad (3.16)$$

şeklinde yazılır.

k. adımdan (k+1). adıma geçişte $w_{ij}(k+1)$ ağırlık değişimi;

$$w_{ij}(k+1) = w_{ij}(k) + \eta \delta_j(k) x_i(k) \quad (3.17)$$

olarak elde edilir. Eşitlik 3.17; geri yayılım algoritmasının en genel ifadesidir. Basit bir metot olan öğrenme oranının artırılmasında, kararsızlık tehlikesinden kaçınmak için, α , momentum katsayısını içeren, Eşitlik 3.15'in düzenlenmiş hali aşağıdaki gibidir:

$$\Delta w_{ij}(k) = \alpha \Delta w_{ij}(k-1) + \eta \delta_j(k) x_i(k) \quad (3.18)$$

Burada momentum katsayısı, genellikle pozitif bir sayı olarak kullanılır. Eşitlik 3.18'de, Eşitlik 3.15'den farklı olarak, ağırlıkların önceki değeri de yeni ağırlıkta etkili olmaktadır. Eşitlik 3.18; genelleştirilmiş delta kuralı olarak ifade edilmektedir (Haykin 1999).

Geri yayılım algoritmasını kullanan GYYSA'nın öğrenme performansı ve tasarımı ilgili olarak belirlenmesi gereken önemli faktörler aşağıda özetlenmiştir.


- **Öğrenme oranı ve momentum katsayısı:** Öğrenme oranı (η), GYYSA'nın eğitim sürecinde, ağırlık değerlerindeki değişimi denetleyen bir tasarım parametresidir. Öğrenme oranının çok büyük olması, her bir tekrarlama (iterasyon) sonunda ayarlanan ağırlık değerlerindeki değişimin büyük olmasına neden olmakta ve hata oranı, en küçük değere indirgenememektedir. Öğrenme oranının çok küçük bir değer olması durumunda ise en küçük hata değerine ulaşılması, uzun zaman almaktadır. Ağırlık değerlerindeki değişimi etkileyen tasarım parametrelerinden biri olan momentum katsayısı (α), öğrenme oranının arttırılarak, öğrenme sürecinin hızlandırılmasını sağlamaktadır. Her tekrarlama için ağırlık değerindeki değişimin, önceki tekrarlama meydana gelen ağırlık değerindeki değişimden hangi ölçüde etkilendiği momentum katsayısı tarafından belirlenmektedir. Bu katsayının büyük olması, her bir tekrarlama sonunda meydana gelen ağırlık değişiminin, bir önceki tekrarlama meydana gelen ağırlık değişiminden daha fazla etkilenmesine neden olmaktadır. Bununla birlikte GYYSA'nın, genel hata oranını dikkate almasını sağlamakta ve noktasal olarak en küçük hata değerine ulaşıldığında, ağırlık öğrenme aşamasının sona ermesini engellemektedir (Liu et al. 2003).

Öğrenme oranı ve momentum katsayısının seçimi için kesin bir kural bulunmamakta olup genellemeler yapılabilmektedir. Kavzoğlu ve Saka (2005) tarafından yapılan çalışmada, öğrenme katsayısı; 0,2 ve momentum katsayısı; 0,6 olarak seçilmiştir. Deneme-yanılma metodu kullanılarak farklı öğrenme oranları ve momentum katsayıları

ile ağırlıkları uygun hale getiren GYYSA yapısı tespit edilebilmektedir (Poulton 2001).

- **Başlangıç ağırlık değerleri:** GYYSA'nın eğitim sürecinin başlangıcında, nöronlar arasındaki ilişkiyi sağlayan ağırlık katsayılarına ilk olarak, rastgele küçük değerler atanır. Atanan başlangıç ağırlık değerlerinin büyük olması durumunda, eğitim işleminin başında, aktivasyon fonksiyonu doygunluğa ulaşabileceğinden, geri yayılım algoritması ilk yerel minimum (local minimum) noktasında tıkanır. Başlangıç ağırlık değerleri, GYYSA'nın öğrenme hızını ve istenilen çıktılara yakınsamasını etkilemektedir. Başlangıç ağırlıkları için uygulanan kesin bir kural bulunmamakla birlikte genel olarak önerilen yöntem, bağlantı ağırlıklarının $[-3/\sqrt{p_i}; 3/\sqrt{p_i}]$ aralığında olmasıdır. Burada p_i , i. nöronun girişine gelen bağlantı sayısıdır (Canan 2006). Kavzoğlu ve Saka (2005) tarafından, başlangıç ağırlık değerlerinin, $[-0,15; 0,15]$ aralığında rastgele seçilmesi önerilmiştir.

- **Gizli katmandaki nöron sayısı:** GYYSA'nın öğrenme sürecinde, gizli katmandaki nöronlar, bağımsız değişkenler (girdiler) ile bağımlı değişken (çıkıtı) arasındaki karmaşık ilişkilerin modellenmesini sağlar. Bu nedenle, GYYSA tarafından üretilen çıktıdaki hatanın minimize edilmesi amacıyla en uygun gizli nöron sayısı tespit edilmelidir. Gizli katmanda fazla sayıda nöron kullanılması durumunda eğitim setindeki hata miktarı küçük olacaktır. Fakat aynı GYYSA'da kullanılan test seti için, eğitim setinin hatası kadar küçük bir hataya ulaşılamayabilir (Özaydın 2009). Fazla gizli nöron sayısı ile test setinin hatası belirli bir değere kadar indirgenmekte fakat daha sonra bu hata oranı artmaya başlamaktadır (Şekil 3.2).



Şekil 3.2 Gizli katmandaki nöron sayısına göre eğitim ve test setlerinin hata eğrileri

Gizli katmandaki nöron sayısının artırılması durumunda GYYSA'nın yapısı karmaşıklaşmakta fakat bununla birlikte hata oranı azalmaktadır. GYYSA'nın gizli

katmanındaki nöronların sayısının belirlenmesi için özel bir kural yoktur fakat başlangıç noktası olarak kullanılabilecek bazı genellemeler bulunmaktadır. Bu nedenle, hatayı minimuma indirgeyen gizli nöron sayısı, deneme-yanılma metodu kullanılarak tespit edilmektedir (Panchal et al. 2011).

- **Eğitim setinin boyutu:** Birçok veri işleme alanında olduğu gibi GYYSA’da da, doğru çözüme ulaşmak için doğru verilere ihtiyaç vardır. Eğer girdi veri kümesi, problemi yeterince iyi karakterize edemiyorsa, GYYSA problemi çözmede yetersiz kalacaktır. GYYSA, girdi uzayından çıktıları oluşturan yani veri uzayını haritalayan bir sistem olarak düşünülebilir. Ancak veri uzayının her bölgesini kapsayan girdi verileri ile çıktı verileri sağlıklı bir şekilde elde edilebilir. Bütün girdi uzayını kapsayan veri setini elde etmek büyük zaman ve maliyet gerektirir. Ayrıca girdi uzayının her bölgesinden veri bulunması da tek başına yeterli değildir. Yüksek boyutlu girdi seti, GYYSA’nın öğrenme sürecini uzatır ve girdi uzayının istenilmeyen bölgelerinin de öğrenilmesine sebep olur. Bundan dolayı girdi verilerinin uygun yöntemlerle seçilmesi gerekir. Bu yöntemlerden birisi girdi uzayını oluşturan verilerin kullanılması yerine, bu verileri kullanarak çıkarılan öznitelik vektörlerinin kullanılmasıdır. Bu yöntem, eğitim sürecinin daha verimli olmasını sağlayabilir. Bir başka yöntem ise girdi verilerini oluşturan ölçümlerden birbirine yakın olanların, ölçüm sınırları dışında olanların ve çok gürültülü olanların girdi veri uzayından ayıklanarak eğitim seti boyutunun küçültülmesidir (Canan 2006).

- **Girdi değerlerinin standartlaştırılması:** GYYSA’nın öğrenme sürecinin hızlandırılması için girdi değerleri arasında ilişki olmaması ve girdi değerlerinin standartlaştırılması gerekmektedir. Bu işlem girdi verilerinin aktivasyon fonksiyonunun aktif bölgesinden aktarılmasını sağlar yani girdi veri kümesinin bir bölgede yoğunlaşmasını engeller. Girdi değerlerinin standartlaştırılması için aşağıda örneklerin aralarında bulunduğu birçok yöntem kullanılabilmekte olup veri yapısına göre en uygun standartlaştırma yöntemi belirlenmelidir.

$$a) \quad x_{st} = \frac{x_i - x_{\min}}{x_{\max} - x_{\min}} \rightarrow [0,1]$$


$$b) \quad x_{st} = \frac{x_i}{x_{\max}} \rightarrow [0,1]$$

Çıktı ya da bağımlı değişken değerleri ise sigmoid aktivasyon fonksiyonu kullanılması

durumunda bu fonksiyonun aralığında standartlaştırılmalıdır. Aksi takdirde geri yayılım algoritması, GYSSA ağırlıklarını sonsuza götürme eğiliminde olacak ve gizli katmandaki nöronların doygunluğa ulaşmasıyla, öğrenme süreci yavaşlayacaktır.


- **Öğrenme sürecinin sonlandırılması:** Öğrenme sürecini sonlandırmanın en kolay yolu, tekrarlama sayısının sınırlandırılmasıdır. Fakat bu yöntemle elde edilen katsayıların en iyi olduklarından asla emin olunamaz. Öğrenme sürecini sonlandırmak için kullanılabilecek alternatif bir ölçüt ise hata düzeyi için bir eşik değeri belirlenmesidir. Fakat öğrenme sürecinde bu eşik değeri elde edilemeyebilir ve bu nedenle öğrenme süreci hiç sonlanmayabilir. Bu gibi sakıncaları ortadan kaldırmak için eğitim setine ait olmayan bir test setiyle GYSSA'nın öğrenme düzeyinin ne kadar iyi olduğu araştırılır. Geri yayılım algoritmasının temeli, ağırlıklar ve GYSSA'nın nöronlarından oluşan girdi-çıkı gösterimini modellemektir. Geleceğe yönelik genelleştirme yapmak için, girdilerle ilgili bilgilerin yeterince öğrenilmesi amacıyla GYSSA'nı yapısı iyi tasarlanmalıdır. Yani öğrenme süreci, girdiler için en iyi parametrelere sahip GYSSA yapısının seçimi anlamına gelmektedir. GYSSA'da böyle bir yapıyı oluşturmak için yol gösterici olarak test veri seti kullanılır.

Geri yayılım algoritmasında, kritik bir noktadan sonra GYSSA, eğitim setindeki veriyi daha iyi öğrendiği için eğitim hatası azalmaya başlar. Test setinde ise kritik noktaya kadar test hatası düşer fakat daha sonra GYSSA, eğitim setindeki veriyi ezberlemeye başladığı için test hatası yükselmeye başlar. Bu durum aşırı uyum (overfitting) veya ezberleme (memorizing) olarak adlandırılır. GYSSA'lar, kontrol altına alınmazlarsa, her zaman ezberlemeye eğilimlidir. Bu problemi çözmek için GYSSA, eğitim seti dışında bir test setiyle periyodik olarak kontrol edilmeli ve öğrenme süreci, test setindeki en küçük hata noktasında sonlandırılmalıdır (Şekil 3.3) (Efe ve Kaynak 2004).



Şekil 3.3 Öğrenme sürecini sonlandırma aralığı

GYYSA eğitimi için kullanılan standart geri yayılım algoritmasında izlenen adımlar Şekil 3.4’de verilmektedir.




Şekil 3.4 Geri yayılım algoritması için akış diyagramı

3.1.2 Radyal Bazlı Fonksiyon Sinir Ağı

RBFSA’nın temeli, sınıflandırma ve fonksiyon yakınsama yapıları olarak, çok değişkenli bir interpolasyon probleminin çözümü için Powel (1987) tarafından oluşturulmuş, Broomhead ve Lowe (1988) ile Moody ve Darken (1989) tarafından ÇKA’ya alternatif bir YSA modeli olarak geliştirilmiştir. RBFSA; biyolojik sinir sistemindeki nöronların yerel etki-tepki davranışlarından esinlenerek oluşturulan yerel algılayıcı alanlar ile fonksiyonların projeksiyonunu sağlamaktadır (Poggio and Girosi 1990). Şekil 3.5’de yapısı verilen RBFSA, bir girdi katmanı, bir gizli katman ve bir çıktı

katmanı olarak üç katmandan oluşur. Girdi katmanı kaynak noktalarından (sensory units) oluşur. Gizli katman ise farklı amaçlara hizmet eden, yeteri kadar yüksek boyuta sahip bir katmandır. Çıktı katmanı ise RBFSA'nın sonucunu sağlar. Gizli katman uzayından çıktı uzayına dönüşüm doğrusal iken, girdi uzayından gizli katman uzayına dönüşüm doğrusal değildir (Haykin 1999).



Şekil 3.5 Radyal bazlı fonksiyon sinir ağı

RBFSa tasarımı, çok boyutlu uzayda eğri uydurma yaklaşımı olarak değerlendirilebilir. Bu nedenle RBFSa'nın eğitimi, çok boyutlu uzayda eğitim setine en uygun yüzeyi bulma problemi olarak ele alınır. RBFSa'nın genellemesi ise, test verilerinin enterpolasyonu amacıyla, eğitim sürecinde bulunan çok boyutlu yüzeyin kullanılmasına eşdeğerdir. Girdi katmanından gizli katmana dönüşüm, radyal bazlı aktivasyon fonksiyonları ile doğrusal olmayan sabit bir dönüşümdür. Gizli katmandan çıktı katmanına ise uyarlamalı ve doğrusal bir dönüşüm gerçekleştirilir.

RBFSa'nın genel matematiksel ifadesine göre, RBFSa'nın gizli katmanındaki i . nöronun çıktı değeri;

$$y_i = G_i(x) = G\left(\frac{\|x - c_i\|}{\sigma_i}\right), i=1,2,\dots,H \quad (3.19)$$

ile hesaplanır. Burada, $\|\cdot\|$, Öklid (Euclidean) normu olmak üzere x ; N -boyutlu girdi vektörü, c_i ; i . radyal bazlı fonksiyonun merkezi, H ; gizli katmandaki nöron sayısı ve

$G_i(\cdot)$; i. nöronun, merkez noktasında tek maksimum değere sahip aktivasyon fonksiyonudur. Genel olarak $G_i(\cdot)$, aşağıda matematiksel ifadesi verilen,

$$G_i(x) = e^{-\left[\frac{(x-c_i)^2}{\sigma_i^2}\right]} \quad (3.20)$$

Gauss fonksiyonu olarak seçilir (Buhmann 2004, Bishop 2005, Blackwell and Chen 2009). σ_i , i. radyal bazlı fonksiyonun genişliğini kontrol eden merkez yayılım parametresidir. Böylece, gizli katmandaki i. nöronun hesapladığı radyal bazlı fonksiyonun değeri y_i , x girdi vektörü elemanın merkezi c_i 'ye en yakın olduğu zaman en büyük değerini alır. RBFSA'nın toplam çıktısı;

$$f(x) = \sum_{i=1}^H f_i w_i = \sum_{i=1}^H f_i G_i(x) \quad (3.21)$$

şeklinde hesaplanır. Burada f_i , gizli katmandaki i. nöronun fonksiyonel çıktı değeridir.

RBFSa'da uyarlanabilecek serbest parametreler; merkez vektörleri, radyal bazlı fonksiyonların genişliği ve çıkış katmanı ağırlıklarıdır. Çıkış katmanı doğrusal olduğu için ağırlıklar, eğim düşme ya da doğrusal en iyileme yöntemleri ile kolayca bulunabilir. Merkezler, girişler arasından rastgele ve sabit olarak seçilebilmekle birlikte RBFSA'nın performansını iyileştirmek amacıyla merkez vektörlerinin ve genişliğinin uyarlanması için çeşitli yöntemler geliştirilmiştir. Merkez vektörleri, eğim düşme yöntemine göre danışmalı öğrenme algoritması ile uyarlanarak veya en küçük kareler algoritması ile giriş örneklerinden öbekleme yapılarak belirlenebilir (Aslanargun et al. 2007).

3.1.3 GYYSA ile RBFSA'nın Karşılaştırılması

GYRSA ve RBFSA'nın her ikisi de, doğrusal olmayan katmana sahip, ileri beslemeli ağ örneği olup, yaygın olarak kullanılan evrensel fonksiyon yakınsayıcılarıdır. Bununla birlikte aralarında yapısal olarak farklılıklar bulunmaktadır. Bu farklılıklar genel olarak;

1) GYYSA, bir ve birden fazla gizli katmana sahip olabilirken, RBFSA, sadece tek bir gizli katmana sahip olabilmektedir.

2) GYYSA'nın gizli katmanında ya da çıktı katmanında yer alan nöronlar, genel bir nöron modeli kullanır. RBFSA'nın gizli katmanındaki nöronlar ise oldukça farklı yapıya sahiptir ve çıktı katmanı da farklı bir amaca hizmet eder.

3) RBFSA'nın gizli katmanı doğrusal yapıda değildir fakat çıktı katmanı doğrusaldır. Genellikle doğrusal olmayan yapıya sahip olan GYYSA'nın gizli ve çıktı katmanları sınıflandırıcı olarak kullanılır. Bununla beraber doğrusal olmayan regresyon problemlerinin çözümünde GYYSA kullanıldığında, genellikle doğrusal bir çıktı katmanı tercih edilir.

4) RBFSA'nın her bir gizli nöronun aktivasyon fonksiyonunun hesaplanması sırasında girdi değeri ile merkez birim arasındaki Öklid mesafesi kullanılır. GYYSA'da ise her bir gizli nöron için aktivasyon fonksiyonu, net girdiye ait bağlantı ağırlık vektörünü hesaplar.

5) GYYSA, doğrusal olmayan girdi-çıkı tasarımı ile global yaklaşımlar oluştururken RBFSA, doğrusal olmayan girdi-çıkı tasarımı ile yerel özelliklerin modellenmesinde kullanılır.

6) Aynı girdi veri setini kullanan RBFSA, GYYSA'ya göre daha kısa sürede öğrenme sürecini tamamlar.

Sonuç olarak, RBFSA'nın çıktı katmanına ait doğrusal yapısı, GYYSA'dan çok Rosenblatt (1958)'in algılayıcı yapısına daha yakın olduğu anlamına gelir. Fakat RBFSA, giriş boşluğunun rastgele seçilmiş non-lineer dönüşümlerini yürütme yeteneğine sahip algılayıcılardan farklıdır. Bu durum, herhangi bir doğrusal algılayıcıyla değil fakat RBFSA ile çözülebilen XOR problemi ile tarif edilebilir (Haykin 1999).

3.2 Kriging Enterpolasyon Yöntemi

İstatistik biliminin uygulamalı bir dalı olup, yerbilimlerinde karşılaşılan kestirim problemlerinin çözümüne yönelik olarak ortaya çıkan jeostatistik (Matheron 1963) kapsamında yer alan mekansal kestirimin temeli; Tobler (1970)'in, coğrafyanın ilk yasası sayılan “her şey diğer her şeyle ilgilidir fakat yakın şeyler uzak şeylerden daha ilgilidir” teorisine dayanmaktadır. Klasik istatistiksel yöntemlerden farklı olarak, mekansal kestirim; örnekler arasındaki ilişkiyi, örnekleme noktalarının koordinatlarını ve örnekler arası korelasyonu hesaba katarak ele alır. Mekansal kestirimde kullanılan deterministik ve stokastik yöntemler arasında en yaygın olanı KRIG enterpolasyon yöntemidir (Joseph 2006).

KRIG yöntemi, ilk olarak Krige (1951) tarafından maden rezervi derece değişimlerinin tespiti için geliştirilmiş ve daha sonra yer bilimlerinde yaygın olarak kullanılmıştır. Matheron (1963), KRIG yöntemini, en iyi mekansal doğrusal kestirim yöntemi olarak belirtmiştir. KRIG, matematiksel jeodezide kollokasyon olarak bilinen en iyi lineer yansız hesaplayıcı (best linear unbiased estimator) ya da en iyi lineer yansız kestirimci (best linear unbiased predictor) olarak tanımlanır (Boogart and Schaeben 2002). KRIG, bilinen yakın noktalardan alınan verileri kullanarak diğer noktalardaki verilerin optimum değerlerini kestiren bir enterpolasyon yöntemidir (Barton et al. 1999). KRIG, diğer enterpolasyon yöntemlerine göre daha yansız sonuçlarının yanı sıra minimum varyansın ve kestirime ait standart sapmanın hesaplanmasına olanak vermektedir (Yaprak 2007). KRIG, birçok alanda kullanılabilirliğini ve popüleritesini kanıtlamış, jeostatistiksel ve esnek bir enterpolasyon yöntemidir (Güllü et al. 2011a).

KRIG, bir bölgede enterpole edilecek olan değerlerin bölgesel bir değişken olduğunu kabul eder ve birbirine yakın örneklerdeki verilerin daha korelasyonlu olması için bölgesel değişken, sürekli bir konumsal çeşitlilik gösterir. KRIG yönteminde en uygun ağırlıkları bulmak için, ölçme noktaları arasındaki konumsal bağımlılığın bilinmesi gerekir. Bu konumsal bağımlılık, kovaryans veya variogram fonksiyonu kullanılarak tanımlanabilir. KRIG, daha yakın noktalardan daha fazla etkilenmeyi sağlayan bir ağırlık modeli kullanır (İnal ve Yiğit 2003).

Örnekleme noktalarının sayısı, dağılımı, ölçü kalitesi, örnekleme noktaları ile kestirilecek noktalar arasındaki yakınlık-uzaklık ilişkisi; KRIG yönteminin doğruluğu ve geçerliliği üzerinde büyük etki sahibidir.

KRIG yöntemi ile belirlenen ağırlıklar, kestirim değerini doğrudan etkilemektedir. Bu nedenle, kestirim değerinin iyi olması için ağırlıkların yansız olması gerekmektedir. KRIG yönteminin en iyi lineer yansız hesaplayıcı olarak tanımlanmasının nedeni, ağırlıkların kestirim hatasının minimum olmasını sağlayacak şekilde belirlenmesidir. Bu durum KRIG yöntemini, diğer yöntemlerden ayıran en önemli özelliklerden bir tanesidir (Isaaks and Srivastava 1989).

KRIG yönteminin genel matematiksel ifadesi;

$$\hat{Z}(x_0) = \sum_{i=1}^N w_i Z(x_i) \quad (3.22)$$

şeklindedir. $\hat{Z}(x_0)$; x_0 noktasının kestirim değeri, w_i ; her bir $Z(x_i)$ 'ye karşılık gelen ağırlık değeri, $Z(x_i)$; değişkenin x_i noktasında gözlenen değeri ve N ; $\hat{Z}(x_0)$ 'ın kestiriminde kullanılan nokta sayısını ifade etmektedir.

KRIG yönteminde temel problem w_i ağırlıklarının en uygun şekilde belirlenmesidir. Söz konusu ağırlıklar; kestirim hatalarının ortalamasının sıfır olması (yansızlık) ve hata varyansının minimum olması koşulları doğrultusunda belirlenmektedir.

Yansızlık koşuluna göre;

$$E[Z(x_0) - \hat{Z}(x_0)] = 0 \quad (3.23)$$

olmalıdır. Buradan,

$$\begin{aligned} E[Z(x_0) - \hat{Z}(x_0)] &= E\left[Z(x_0) - \sum_{i=1}^N w_i Z(x_i)\right] = E[Z(x_0)] - \sum_{i=1}^N w_i E[Z(x_i)] = 0 \\ E[Z(x_0)] &= \sum_{i=1}^N w_i E[Z(x_i)] \Rightarrow \mu = \sum_{i=1}^N w_i \mu \Rightarrow \sum_{i=1}^N w_i = 1 \end{aligned} \quad (3.24)$$

elde edilir.

Hata varyansı; $\text{Var}[Z(x_0) - \hat{Z}(x_0)] = E[Z(x_0) - \hat{Z}(x_0)]^2$ olmak üzere, minimum hata varyansı koşuluna göre;

$$E\left[Z(x_0) - \sum_{i=1}^N w_i Z(x_i)\right]^2 = -\sum_{i=1}^N \sum_{j=1}^N w_i w_j \frac{1}{2} E[Z(x_i) - Z(x_j)]^2 + 2 \sum_{j=1}^N w_j \frac{1}{2} E[Z(x_0) - Z(x_j)]^2 = 0 \quad (3.25)$$

eşitliği elde edilir. Burada $\text{Var}[Z(x_0)] = \text{Var}[\hat{Z}(x_0)]$ olmak üzere variogram fonksiyonu,

$$\gamma(h) = \frac{1}{2} E[Z(x) - Z(x+h)]^2 \quad (3.26)$$

olmaktadır. Eşitlik 3.26 göz önüne alınarak,

$$E\left[Z(x_0) - \sum_{i=1}^N w_i Z(x_i)\right]^2 = -\sum_{i=1}^N \sum_{j=1}^N w_i w_j \gamma(x_i - x_j) + 2 \sum_{j=1}^N w_j \gamma(x_0 - x_j) \quad (3.27)$$

elde edilir. Eşitlik 3.27'nin en küçüklenmesi, yansızlık koşulu altında, bir optimizasyon problemi olarak ele alınır ve Lagrange çarpanları yönteminin kullanımı ile çözülebilir (Tosunoğlu 2007). Bu durumda (N) bilinmeyenlerden oluşan (N+1) denklemlili KRIG sistemi elde edilir. Bu sistem;

$$\sum_{i=1}^N w_i \gamma(x_i - x_j) + \lambda = \gamma(x_0 - x_j); j=1,2,\dots,N; \sum_{i=1}^N w_i = 1 \quad (3.28)$$

biçimindedir. Eşitlik 3.28'deki λ ; sistem çözümünün yansız olması için eklenen Lagrange çarpanıdır. $\gamma(x_i - x_j) = \gamma_{ij}$; x_i noktası ile x_j noktası arasındaki mesafeye bağlı yarı variogram olmak üzere, KRIG sistemi;

$$\begin{array}{ccccccccc} w_1 \gamma_{11} & + & w_2 \gamma_{12} & + & \dots & + & w_N \gamma_{1N} & + & \lambda & = & \gamma_{10} \\ w_1 \gamma_{21} & + & w_2 \gamma_{22} & + & \dots & + & w_N \gamma_{2N} & + & \lambda & = & \gamma_{20} \\ \vdots & & \vdots & & \vdots & & \vdots & & \vdots & & \vdots \\ w_1 \gamma_{N1} & + & w_2 \gamma_{N2} & + & \dots & + & w_N \gamma_{NN} & + & \lambda & = & \gamma_{N0} \\ w_1 & + & w_2 & + & \dots & + & w_N & & & = & 1 \end{array} \quad (3.29)$$

şeklinde yazılabilir.

$$\gamma = \begin{bmatrix} \gamma_{11} & \gamma_{12} & \dots & \gamma_{1N} & 1 \\ \gamma_{21} & \gamma_{22} & \dots & \gamma_{2N} & 1 \\ \vdots & \vdots & \vdots & \vdots & \vdots \\ \gamma_{N1} & \gamma_{N2} & \dots & \gamma_{NN} & 1 \\ 1 & 1 & \dots & 1 & 0 \end{bmatrix}, w = \begin{bmatrix} w_1 \\ w_2 \\ \vdots \\ w_N \\ \lambda \end{bmatrix}, \gamma_0 = \begin{bmatrix} \gamma_{10} \\ \gamma_{20} \\ \vdots \\ \gamma_{N0} \\ 1 \end{bmatrix} \quad (3.30)$$

olmak üzere, KRIG sistemi matris formunda;

$$\gamma \cdot w = \gamma_0 \quad (3.31)$$

şeklini alır. Buradan w; bilinmeyenler (ağırlıklar) matrisi;

$$w = \gamma^{-1} \cdot \gamma_0 \quad (3.32)$$

denklem sistemine göre çözümlenir.

Ağırlıklar belirlendikten sonra, Eşitlik 3.22 kullanılarak, çalışma bölgesindeki herhangi bir x_0 noktası için kestirim değerini elde etmekte kullanılan nokta sayısı, hesaplanacak ağırlıkların sayısını etkilemektedir. Her bir dayanak noktası için bir ağırlık hesaplanmaktadır. Aynı dayanak noktalarını kullanan farklı konumlardaki noktaların ağırlıkları farklı olmaktadır. Bu durum KRIG algoritmasında her bir yeni nokta için ağırlık hesabının tekrarlı olarak bulunması anlamına gelmektedir (İnal ve Yiğit 2003).

KRIG yöntemi ile yapılan kestirimin varyansı (KRIG varyansı);

$$\sigma_K^2 = 2 \sum_{i=1}^N w_i \gamma(x_0 - x_i) - \sum_{i=1}^N \sum_{j=1}^N w_i w_j \gamma(x_i - x_j) = \sum_{i=1}^N w_i \gamma(x_0 - x_i) + \lambda \quad (3.33)$$

şeklinde hesaplanır.

KRIG yönteminde, hesaplanan KRIG varyansı aracılığı ile kestirim hatasının büyüklüğü değerlendirilebilir. KRIG varyansı, kullanılan veri sayısının ve verilerin konumları arasındaki uzaklığın bir fonksiyonu olup, verilerin gerçek değerlerine bağlı değildir. Bu kapsamda KRIG varyansı, verilerin gerçek değerlerinin elde edilmesinden önce olası noktaların test edilip, optimum noktaların belirlenmesi amacıyla kullanılabilir (Tosunoğlu 2007).

KRIG yönteminin diğer kestirim yöntemlerine göre en önemli üstünlüğü, esnek yapısıdır. Ağırlıkların seçimi belirli koşullara bağlıdır. Kullanılacak verilerin sistemli ve objektif bir şekilde analiz edilmesi ile belirlenen variogram fonksiyonu yardımıyla ağırlıklar belirlenir (İnal ve Yiğit 2003).

4. JEODEZİK NOKTA HIZ KESTİRİM METODOLOJİSİ


4.1 Uygulamanın Amacı

Bu çalışma kapsamında gerçekleştirilen uygulamanın amacı; çalışma alanı olarak seçilen Türkiye'nin orta ve batı Anadolu bölümlerinde oluşturulan jeodezik ağlarda, GYYSA, RBFSA ve KRIG yöntemleri ile kestirilen nokta hızlarını, HGK tarafından belirlenmiş nokta hız değerleri ile karşılaştırmak suretiyle, YSA'nın jeodezik nokta hızlarının kestirimi probleminde kullanılabilirliğinin araştırılmasıdır.

4.2 Çalışma Alanı ve Veri Seti

Uygulamanın gerçekleştirildiği çalışma alanı olarak; Türkiye'nin orta ve batı Anadolu bölümlerini kapsayan, $36^{\circ},95 < \varphi < 40^{\circ},50$; $27^{\circ},10 < \lambda < 32^{\circ},75$ coğrafi sınırlar arasındaki, yaklaşık 380 km x 480 km ($\sim 182\,500\text{ km}^2$) yüzölçümlü bölge seçilmiştir (Şekil 4.1).

Çalışma alanında bulunan ve konumsal dağılımları Şekil 4.1'de gösterilen, toplam 125 adet TUTGA noktasının coğrafi koordinatları ile HGK tarafından belirlenmiş ve BÖHHBÜY'ne göre mevcut büyük ölçekli harita üretim faaliyetlerinde kullanılmakta olan V_X , V_Y , V_Z hız değerleri, uygulama veri seti olarak düzenlenmiştir.



Şekil 4.1 Çalışma alanı ve jeodezik noktaların coğrafi dağılımı

Aşağıdaki eşitlik ile tanımlanan V_X , V_Y , V_Z hız değerlerine ilişkin istatistiki değerler Çizelge 4.1’de verilmektedir.

$$V_{X,Y,Z} = \frac{X, Y, Z_{(t)} - X, Y, Z_{(t_0)}}{(t - t_0)} \quad (4.1)$$

Burada t ; ölçüm epokunu, t_0 ; referans epokunu ifade etmektedir. Genel olarak $V_{X,Y,Z}$ hız değerleri; (mm/yıl) şeklinde hesaplanmaktadır (Kurt ve Deniz 2010).

Çizelge 4.1 Uygulama kapsamındaki jeodezik nokta hızlarının istatistiksel değerleri (mm/yıl)

	V_X	V_Y	V_Z
Minimum	-21,8	-13,1	-12,0
Maksimum	11,5	10,6	14,3
Ortalama	-4,3	0,3	2,7
Standart sapma	7,4	3,7	5,9

4.3 Uygulama Metodolojisi


Bu çalışma kapsamında; toplam 125 adet TUTGA noktasından oluşturulan veri seti uygulama için, referans ve test olarak iki ayrı alt sete ayrılarak kullanılmıştır. Referans veri seti; GYYSA ile RBFSA’nın eğitiminde ve KRIG yönteminde hız yüzeyinin oluşturulmasında kullanılmıştır. Test veri seti ise eğitilmiş GYYSA ve RBFSA’nın performansının değerlendirilmesinde ve KRIG yönteminin kestirim doğruluğunun belirlenmesinde kullanılmıştır.

GYYSA ile RBFSA’nın eğitiminde ve KRIG yöntemi için hız yüzeyi modelinin oluşturulmasında kullanılan referans veri setindeki nokta yoğunluğunun jeodezik noktaların hız kestirimine olan etkisini değerlendirebilmek amacıyla mevcut veri setinden beş farklı jeodezik ağ modeli oluşturularak (Çizelge 4.2), tüm V_X , V_Y , V_Z hız kestirimleri bu beş model üzerinde gerçekleştirilmiştir.


Çizelge 4.2 Oluşturulan jeodezik ağ modelleri

Model	Nokta Sayısı		Nokta Yoğunluğu (km ² /nokta)	
	Referans	Test	Referans	Test
1	20	105	~ 9 000	~ 1 750
2	40	85	~ 4 500	~ 2 150
3	60	65	~ 3 000	~ 2 800
4	80	45	~ 2 250	~ 4 050
5	100	25	~ 1 825	~ 7 300


Çizelge 4.2’de verilen beş model üzerinde, çalışma alanını dıştan çevreleyecek ve hız alanını karakterize edebilecek şekilde oluşturulan referans veri setinin ve referans noktalarının oluşturduğu jeodezik ağın içinde kalan ve sıklaştırma noktası olarak değerlendirilebilecek şekilde oluşturulan test veri setinin nokta dağılımları, Şekil 4.2, 4.3, 4.4, 4.5 ve 4.6’da görülmektedir.




Şekil 4.2 1 no’lu jeodezik ağ modeli ($\Delta \rightarrow$ Referans; $o \rightarrow$ Test)




Şekil 4.3 2 no’lu jeodezik ağ modeli ($\Delta \rightarrow$ Referans; $o \rightarrow$ Test)



Şekil 4.4 3 no'lu jeodezik ağ modeli ($\Delta \rightarrow$ Referans; o $\rightarrow$ Test)



Şekil 4.5 4 no'lu jeodezik ağ modeli ($\Delta \rightarrow$ Referans; o $\rightarrow$ Test)




Şekil 4.6 5 no'lu jeodezik ağ modeli ($\Delta \rightarrow$ Referans; o $\rightarrow$ Test)


Jeodezik ağlarda nokta hızlarının GYYSA ve RBFSA ile kestiriminde ilk olarak, girdi ve çıktı veri setleri oluşturulmuştur. Referans ve test noktalarının coğrafi koordinatları (ϕ , λ), girdi verisi olarak ve noktanın her bir $V_{X,Y,Z}$ hız bileşeni, çıktı verisi olarak kullanılmıştır. Yeterli sayıda nöron kullanıldığında tek gizli katmana sahip YSA yapısı sürekli fonksiyonları yakınsayabildiği için (Cybenko 1989, Funahashi 1989, Hornik et al. 1989, Bishop 2005) ve sadece sürekli bir yapıya sahip olmayan düzensiz veriler söz konusu olduğunda birden fazla gizli katmana ihtiyaç duyulması nedeniyle (Panchal et al. 2011); çalışma kapsamında kullanılacak GYYSA tek gizli katmanlı olarak tasarlanmıştır. Gizli katmandaki nöron sayısının tespiti için deneme-yanılma metodu kullanılarak, MATLAB YSA modülünde, katmanlardaki nöron sayılarına göre [2:20:1] yapısına sahip GYYSA ve [2:17:1] yapısına sahip RBFSA tasarlanmıştır. Referans noktasının en fazla olduğu Model - 5 üzerinde GYYSA ve RBFSA'nın eğitim işlemi gerçekleştirilerek en küçük HKO'yu üreten, öğrenme oranı, momentum katsayısı ve başlangıç ağırlık değerleri şeklindeki YSA parametreleri; diğer dört model üzerinde gerçekleştirilen eğitim işleminde başlangıç değerleri olarak kullanılmıştır.

KRIG yöntemi ile jeodezik nokta hızlarının kestiriminde, jeodezik ağ modellerindeki referans noktaları kullanılarak her bir $V_{X,Y,Z}$ hız bileşeni için referans hız alanı oluşturulmuş (Şekil 4.7, 4.8, 4.9, 4.10 ve 4.11) ve çapraz-doğrulama (cross-validation) tekniği kullanılarak yani referans veri setinde yer alan her bir noktanın sıra ile veri seti kapsamından çıkarılarak kalan noktalar yardımıyla o noktanın hız kestirimi yapılarak oluşturulan hız alanının doğruluğu kontrol edilmiştir. SURFER yüzey modelleme programı kullanılarak KRIG yöntemi ile test noktalarının hızlarının kestirilebilmesi için, referans hız alanlarına ait V_X , V_Y , V_Z hız yüzeyleri oluşturulmuştur.


KRIG yönteminde fay hatlarını girdi olarak kullanma olanağı olmasına rağmen; HGK tarafından belirlenmiş ve uygulama kapsamında temel hız değeri olarak kullanılan, TUTGA noktalarının hızlarının kestiriminde fay hatları dikkate alınmadan uygulama yapıldığı için (Aktuğ vd. 2011), KRIG yöntemi ile hız kestiriminde, 30-50 km aralıklı kontrol noktaları ile tespiti güç olan fay hatları ve tektonik sınırlar kullanılmamıştır.



(a)




(b)




(c)


Şekil 4.7 Model - 1 referans hız alanı (a $\rightarrow V_x$; b $\rightarrow V_y$; c $\rightarrow V_z$)



(a)




(b)




(c)


Şekil 4.8 Model - 2 referans hız alanı (a $\rightarrow V_x$; b $\rightarrow V_y$; c $\rightarrow V_z$)



(a)




(b)




(c)


Şekil 4.9 Model - 3 referans hız alanı (a $\rightarrow V_x$; b $\rightarrow V_y$; c $\rightarrow V_z$)



(a)




(b)




(c)


Şekil 4.10 Model - 4 referans hız alanı (a $\rightarrow V_x$; b $\rightarrow V_y$; c $\rightarrow V_z$)



(a)



(b)



(c)

Şekil 4.11 Model - 5 referans hız alanı (a $\rightarrow V_x$; b $\rightarrow V_y$; c $\rightarrow V_z$)

Jeodezik ağı modellerindeki referans veri setlerine dayalı olarak eğitilmiş GYYSA ile RBFSA kullanılarak ve referans hız alanlarına göre oluşturulmuş hız yüzeylerine göre KRIG yöntemi kullanılarak söz konusu modellerdeki test noktalarının V_X , V_Y , V_Z hızları hesaplanmıştır. GYYSA ile RBFSA'nın, jeodezik noktaların hızlarının kestirimindeki performansının belirlenebilmesi ve KRIG yöntemi ile kestirilen nokta hızlarının doğruluğunun tespit edilebilmesi amacıyla, test noktalarına ait HGK tarafından TUTGA kapsamında belirlenmiş temel V_X , V_Y , V_Z hız değerleri ile GYYSA, RBFSA ve KRIG ile kestirilmiş V_X , V_Y , V_Z hız değerleri arasındaki hız farkları ($\Delta V_{X,Y,Z}$) aşağıdaki şekilde hesaplanmıştır.

$$\Delta V_{X,Y,Z} = V_{X,Y,Z}(\text{TUTGA}) - V_{X,Y,Z}(\text{GYRSA, RBFSA, KRIG}) \quad (4.2)$$

Elde edilen $\Delta V_{X,Y,Z}$ 'lerin istatistiksel analizi için, minimum, maksimum, ortalama ve KOH değerleri hesaplanmış ve $\Delta V_{X,Y,Z}$ 'ler; hesaplanan ve bilinen model değerleri arasındaki küçük farklara bile duyarlı olan (Yılmaz ve Güllü 2011), enterpolasyon yöntemlerinin hata hesabında global olarak kullanılan (Erdoğan 2010) ve YSA uygulamalarında sonuçların değerlendirilmesinde etkin olan (Wolfram 2005, Schroeder et al. 2009) KOH ölçütüne göre incelenmiştir.

$$\text{KOH} = \sqrt{\frac{1}{n} \sum_{i=1}^n (\Delta V_{X,Y,Z})^2} \quad (4.3)$$

Buradaki n ; hesaplanan hız farkının yani modeldeki test noktasının sayısını ifade etmektedir.

5. UYGULAMA ve BULGULAR


Jeodezik ağılarda nokta hızlarının GYYSA, RBFSA ve KRIG yöntemi ile kestirilmesi uygulamasında; YSA modellerinin eğitiminde ve KRIG için hız yüzeylerinin oluşturulmasında kullanılmayan test veri setinin performansı belirleyici olmaktadır. Bu nedenle, elde edilen sonuçların değerlendirilebilmesi amacıyla jeodezik ağ modellerindeki test noktalarının $V_{X,Y,Z}$ (TUTGA) hız değerleri ile GYYSA, RBFSA ve KRIG ile kestirilmiş hız değerleri arasındaki farklara göre, V_X , V_Y , V_Z hız fark haritaları düzenlenmiştir. Söz konusu haritalar, Şekil 5.1, 5.2, 5.3, 5.4, 5.5, 5.6, 5.7, 5.8, 5.9, 5.10, 5.11, 5.12, 5.13, 5.14 ve 5.15’de verilmektedir. V_X , V_Y , V_Z hız fark haritaları, iki mm aralıklı olarak düzenlenmiş olup, GYYSA, RBFSA ve KRIG’in birlikte değerlendirilebilmesi amacıyla her bir hız bileşeni için her üç yöntem ile hesaplanan farklara ait haritalar aynı şekil bünyesinde verilmektedir.

Model - 1’e ilişkin Şekil 5.1, 5.2 ve 5.3 birlikte değerlendirildiğinde; test noktalarına ait V_X , V_Y , V_Z hız değerlerinin GYYSA tarafından diğer yöntemlere göre daha doğru modellendiği, RBFSA ve KRIG’in sonuçları arasında ise belirgin bir fark bulunmadığı değerlendirilmektedir.


Model - 2 ile ilgili Şekil 5.4, 5.5 ve 5.6 incelendiğinde; GYYSA tarafından test noktalarının V_X , V_Y , V_Z hız değerlerinin daha iyi kestirildiği, KRIG yönteminde, referans hız alanına bağlı olarak, ilk modele göre hız farklarının küçüldüğü ve RBFSA’nın sonuçlarında belirgin bir değişim bulunmadığı anlaşılmaktadır.

Model - 3’e ait Şekil 5.7, 5.8 ve 5.9’dan; GYYSA ve KRIG tarafından test noktalarının V_X , V_Y , V_Z hız değerlerinin RBFSA’ya göre daha iyi modellendiği, kendi aralarında ise belirgin bir fark bulunmadığı değerlendirilmektedir.


Model - 4 ile ilgili Şekil 5.10, 5.11 ve 5.12 değerlendirildiğinde; hız farklarının küçüldüğü ve artan referans noktası nedeniyle, KRIG yöntemi ile test noktalarının V_X , V_Y , V_Z hız değerlerinin diğer yöntemlerden daha iyi kestirildiği anlaşılmaktadır.



(a)






(b)






(c)




Şekil 5.1 Model - 1 V_x hız farkları (a → GYSA; b → RBFS; c → KRIG)




Şekil 5.2 Model - 1 V_Y hız farkları (a → GYSA; b → RBFSA; c → KRIG)




Şekil 5.3 Model - 1 V_z hız farkları (a → GYYSA; b → RBFSA; c → KRIG)




Şekil 5.4 Model - 2 V_x hız farkları (a → GYSA; b → RBFS; c → KRIG)



(a)






(b)




(c)


Şekil 5.5 Model - 2 V_Y hız farkları (a → GYSA; b → RBFS; c → KRIG)




Şekil 5.6 Model - 2 V_z hız farkları (a → GYYSA; b → RBFS; c → KRIG)



(a)






(b)






(c)




Şekil 5.7 Model - 3 V_x hız farkları (a → GYSA; b → RBFA; c → KRIG)






Şekil 5.8 Model - 3 V_Y hız farkları (a → GYSA; b → RBFS; c → KRIG)




Şekil 5.9 Model - 3 V_z hız farkları (a → GYSA; b → RBFSA; c → KRIG)




Şekil 5.10 Model - 4 V_x hız farkları (a → GYSA; b → RBFSA; c → KRIG)




Şekil 5.11 Model - 4 V_Y hız farkları (a → GYSA; b → RBFSA; c → KRIG)



(a)






(b)






(c)




Şekil 5.12 Model - 4 V_z hız farkları (a → GYSA; b → RBFSA; c → KRIG)



Şekil 5.13 Model - 5 V_x hız farkları (a → GYSA; b → RBFSA; c → KRIG)




Şekil 5.14 Model - 5 V_Y hız farkları (a → GYSA; b → RBFSA; c → KRIG)



Şekil 5.15 Model - 5 V_z hız farkları (a → GYSA; b → RBFSA; c → KRIG)

Model - 5'e ilişkin Şekil 5.13, 5.14 ve 5.15 birlikte değerlendirildiğinde; en küçük hız farklarının, kullanılan referans noktasının en fazla olduğu bu modelde elde edildiği, test noktalarının V_X , V_Y , V_Z hız değerlerinin KRIG yöntemi ile diğer yöntemlerden daha iyi kestirildiği, artan referans noktasına rağmen GYYSA ve RBFSA ile hesaplanan hız farklarının doğruluğunun beklenen oranda artmadığı anlaşılmaktadır.

GYYSA, RBFSA ve KRIG yöntemlerinin nokta hız kestirimindeki performanslarının birlikte değerlendirilebilmesi amacıyla, jeodezik ağ modelleri üzerinde hesaplanan V_X , V_Y , V_Z hız farklarının KOH ölçütüne göre karşılaştırılması Şekil 5.16'da verilmiştir.



Şekil 5.16 Hesaplanan hız farklarının KOH değerleri

GYYSA, RBFSA ve KRIG yöntemleri ile elde edilen, test noktalarına ait V_X , V_Y , V_Z hız farklarının kendi aralarında istatistiksel olarak karşılaştırılmasında kullanılmak üzere, söz konusu hız farklarının minimum, maksimum ve ortalama değerleri hesaplanarak, KOH değerleri ile birlikte Çizelge 5.1'de verilmiştir.

Test noktalarına ait V_X , V_Y , V_Z hız farklarının istatistiksel değerlerinin verildiği Çizelge 5.1 incelendiğinde; Şekil 5.16'dan da görülebileceği üzere, çalışma kapsamında oluşturulan beş farklı jeodezik ağ modelinin tümünde GYYSA'nın nokta hız kestirimindeki performansı, RBFSA'dan daha iyidir.

Çizelge 5.1 Hesaplanan hız farklarının istatistiksel değerleri (mm/yıl)

MODEL 1	GYRSA			RBFS			KRIG		
	ΔV_X	ΔV_Y	ΔV_Z	ΔV_X	ΔV_Y	ΔV_Z	ΔV_X	ΔV_Y	ΔV_Z
Minimum	-11,0	-10,3	-12,5	-12,7	-11,0	-10,6	-11,8	-16,0	-12,7
Maksimum	12,1	6,5	11,9	12,7	7,6	13,6	17,2	10,2	14,1
Ortalama	2,0	-0,3	0,9	2,0	-1,5	2,0	2,7	-0,5	2,1
KOH	4,8	3,0	4,1	5,4	3,7	4,6	5,4	3,5	4,5
MODEL 2	GYRSA			RBFS			KRIG		
	ΔV_X	ΔV_Y	ΔV_Z	ΔV_X	ΔV_Y	ΔV_Z	ΔV_X	ΔV_Y	ΔV_Z
Minimum	-10,4	-10,4	-10,1	-14,8	-10,4	-11,7	-10,1	-9,7	-9,9
Maksimum	10,5	5,7	8,2	10,2	8,2	12,5	15,3	8,5	11,5
Ortalama	0,1	0,3	-0,3	-0,2	-1,2	1,0	1,0	0,5	0,5
KOH	3,5	2,5	3,2	4,8	3,6	4,4	4,0	2,8	3,3
MODEL 3	GYRSA			RBFS			KRIG		
	ΔV_X	ΔV_Y	ΔV_Z	ΔV_X	ΔV_Y	ΔV_Z	ΔV_X	ΔV_Y	ΔV_Z
Minimum	-8,0	-4,5	-6,9	-14,5	-7,0	-5,7	-10,0	-9,6	-14,2
Maksimum	7,1	6,0	7,3	10,0	6,5	6,6	9,9	7,4	8,4
Ortalama	-0,5	-0,3	0,6	-0,5	-1,1	-0,1	0,0	0,0	-0,2
KOH	3,1	2,2	2,9	4,7	3,1	3,5	3,1	2,3	3,0
MODEL 4	GYRSA			RBFS			KRIG		
	ΔV_X	ΔV_Y	ΔV_Z	ΔV_X	ΔV_Y	ΔV_Z	ΔV_X	ΔV_Y	ΔV_Z
Minimum	-6,0	-4,4	-5,9	-14,5	-5,8	-5,8	-9,6	-8,0	-8,9
Maksimum	7,8	5,7	7,0	9,7	5,9	7,1	6,3	3,7	4,3
Ortalama	1,0	0,1	0,9	-0,3	-1,2	1,3	0,1	0,0	0,0
KOH	3,1	2,1	2,9	4,5	2,9	3,6	2,4	1,8	2,2
MODEL 5	GYRSA			RBFS			KRIG		
	ΔV_X	ΔV_Y	ΔV_Z	ΔV_X	ΔV_Y	ΔV_Z	ΔV_X	ΔV_Y	ΔV_Z
Minimum	-4,4	-3,1	-5,2	-10,1	-5,7	-6,5	-4,9	-3,6	-5,1
Maksimum	7,3	5,0	7,0	9,4	6,1	6,2	3,7	3,0	3,9
Ortalama	0,5	0,0	0,4	-0,7	-1,2	1,1	0,2	-0,1	0,0
KOH	2,7	1,9	2,7	4,2	2,9	3,6	1,5	1,3	1,6

GYRSA ile ilgili değerler KRIG'e ait değerler ile karşılaştırıldığında; GYRSA'nın nokta hızlarını, referans noktasının test noktasından daha az olduğu ilk üç modelde KRIG'den daha doğru olarak hesapladığı görülmektedir. Referans noktasının test noktasından daha fazla olduğu diğer iki modelde ise KRIG yöntemi, GYRSA'dan daha başarılıdır. RBFS ile kestirilen nokta hızları ise, yalnızca ilk modelde KRIG ile aynı doğruluk seviyesindedir.

6. SONUÇ ve ÖNERİLER

Bu çalışmanın amacı; mekansal kestirim problemi olarak ele alınan jeodezik noktaların hız kestiriminde YSA'nın kullanılabilirliğinin araştırılması olup, çalışma kapsamında elde edilen verilerin tamamı (Şekil 5.1-5.16 ve Çizelge 5.1) birlikte değerlendirildiğinde, jeodezik noktaların hızlarının, jeodezik ağda bulunan ve hız değerleri bilinen diğer noktalara dayalı olarak kestirilmesi probleminde, en küçük KOH değerini veren yöntemin kullanılabilir en iyi yöntem olduğu düşüncesinden hareketle, aşağıdaki sonuçlar çıkarılmış ve önerilerde bulunulmuştur:

- Çalışma kapsamındaki YSA yöntemlerinden GYYSA, genel olarak jeodezik nokta hız kestiriminde kullanılabilir olup RBFSA ise mevcut enterpolasyon yöntemlerine göre tercih edilebilir olarak görülmemektedir.

- Referans noktasının test noktasından az olduğu Model 1, 2 ve 3'de GYYSA ile KRIG'den daha iyi sonuçlar elde edilmiş olup, hız değeri bilinen nokta yoğunluğunun ($3\ 000\text{ km}^2 / \text{nokta}$)'dan küçük olduğu ve geniş alanlarda fazla sayıda noktanın hızlarının kestirilmesine ihtiyaç duyulduğu jeodezik ağ yapılarında, GYYSA'nın etkin bir şekilde kullanılabileceği değerlendirilmektedir.

- Örneklem noktalarının sayısının enterpolasyon yöntemlerinin sonuçları üzerinde doğrudan ve büyük bir etkiye sahip olması nedeniyle, referans noktasının test noktasından fazla olduğu Model 4 ve 5'de KRIG ile daha doğru bir modelleme elde edilmiş olup, hız değeri bilinen mevcut nokta sayısının fazla olduğu jeodezik uygulamalarda KRIG yöntemi verimli olarak kullanılabilmektedir.

- Çalışma kapsamındaki beş model üzerinde, GYYSA ile elde edilen sonuçlar, KRIG ile elde edilen sonuçlarla örtüşmekte olup, referans nokta sayısının artması yani hız değeri bilinen nokta yoğunluğu yüksek jeodezik ağ yapılarının oluşturulması KRIG yönteminin hız kestirimi sonuçlarını GYYSA'ya göre daha pozitif etkilemektedir.

- Jeodezik nokta hız kestirimi problemi için genel kapsamda kullanılabilir olarak değerlendirilen GYYSA'nın KRIG'e göre temel avantajı, esnek yapısı nedeniyle belirli bir matematiksel model izleme zorunluluğunun bulunmaması ve normal dağılımlı olmayan verilere de uygulanabilmesidir.

7. KAYNAKLAR

- Alavala, C.R. (2007). Fuzzy Logic and Neural Networks: Basic Concepts and Applications. New Age International Publishers, New Delhi.
- Aktuğ, B. (2003). ITRF hız alanı ve görelî hız referans sistemlerine bakış. *Harita Dergisi*, **130**: 12-31.
- Aktuğ, B., Sezer S., Özdemir, S., Lenk, O ve Kılıçoğlu, A. (2011). Türkiye Ulusal Temel GPS Ağı güncel koordinat ve hızlarının hesaplanması. *Harita Dergisi*, **145**: 1-14.
- Akyılmaz, O. (2005). Esnek Hesaplama Yöntemlerinin Jeodezide Uygulamaları. Doktora Tezi, İstanbul Teknik Üniversitesi, Fen Bilimleri Enstitüsü, İstanbul.
- Anderson, J.A. (1972). A simple neural network generating on interactive memory. *Mathematical Biosciences*, **14**: 197-220.
- Anderson, D. and McNeill, G. (1992). Artificial neural networks technology. DACS State-of-the-Art Report ELIN: A011, Rome Laboratory, AFB, NY.
- Aslanargun, A., Mammadov, M., Yazıcı, B. And Yolaçan, S. (2007). Comparison of ARIMA, neural networks and hybrid models in time series tourist arrival forecasting. *Journal of Statistical Computation and Simulation*, **77-1**: 29-53.
- Arbib, M.A. (2003). The Handbook of Brain Theory and Neural Networks. The MIT Press, London.
- Ayhan, M.E., Demir, C., Lenk, O., Kılıçoğlu, A., Aktuğ, B., Açıkgöz, M., Fırat, O., Şengün, Y.S., Cingöz, A., Gürdal, M.A., Kurt, A.İ., Ocak, M., Türkezer, A., Yıldız, H., Bayazıt, N., Ata, M., Çağlar, Y. ve Özerkan, A. (2002). Türkiye Ulusal Temel GPS Ağı-1999A (TUTGA-99A). *Harita Dergisi Özel Sayı*, **16**: 1-73.
- Bandara, K.R., Samarakoon, L., Shrestha, R.P. and Kamiya, Y. (2011). Automated generation of digital terrain model using point clouds of digital surface model in forest area. *Remote Sensing*, **3**: 845-858.

- Baronian C., Riahi, M.A., Lucas, C. and Mokhtari, M. (2007). A theoretical approach to applicability of artificial neural networks for seismic velocity analysis. *Journal of Applied Sciences*, **7**: 3659-3668.
- Baronian C., Riahi, M.A. and Lucas, C. (2009). Applicability of artificial neural networks for obtaining velocity models from synthetic seismic data. *International Journal of Earth Sciences*, **98**: 1173-1184.
- Barsi, A. (2001). Performing coordinate transformation by artificial neural network. *Allgemeine Vermessungs Nachrichten*, **4**: 134-137.
- Barton, J.M.H., Buchberger, S.G. and Lange, M.J. (1999). Estimation of error and compliance in surveys by kriging. *Journal of Surveying Engineering*, **125-2**: 87-108.
- Bayraktar, H. (2009). Yapay Sinir Ağlarıyla Uydu Görüntüleri Spektral Bant Aralıklarının Mavi Bant Örneğinde Modellenmesi. Doktora Tezi, Yıldız Teknik Üniversitesi, Fen Bilimleri Enstitüsü, İstanbul.
- Baysal, D., Aktuğ, B. and Koçyiğit, A. (2010). GPS nokta koordinatlarındaki zamana bağlı değişimlerin analizi ve yorumu: İzmir bölgesinde uygulama. *Harita Dergisi*, **144**: 29-39.
- Beale, M.H., Hagan, M.T. and Demuth, H.B. (2010). Neural Network Toolbox 7 User's Guide. The MathWorks Inc., Natick, MA.
- Bishop, C.M. (2005). Neural Networks for Pattern Recognition. Oxford University Press, New York, NY.
- Blackwell, W.J. and Chen, F.W. (2009). Neural Networks in Atmospheric Remote Sensing. Artech House, Norwood, MA.
- Boogaart, K.G. and Schaeben, H. (2002). Kriging of regionalized directions, axes and orientations I. Directions and axes. *Mathematical Geology*, **34-5**: 479-503.
- Broomhead, D. and Lowe, S. (1988). Radial Basis Functions, Multi-Variable Functional Interpolation and Adaptive Networks. Royal Signals and Radar Establishment Memorandum, No.4148.

- Buhmann, M.D. (2004). Radial Basis Functions: Theory and Implementations. Cambridge University Press, Cambridge.
- Calderon-Macias, C., Sen, M.K. and Stoffa P.L. (1998). Automatic NMO correction and velocity estimation by a feedforward neural network. *Geophysics*, **63-5**: 1696-1707.
- Calderon-Macias, C., Sen, M.K. and Stoffa P.L. (2000). Artificial neural networks for parameter estimation in geophysics. *Geophysical Prospecting*, **48**: 21-47.
- Canan, S. (2006). Yapay Sinir ağıları ile GPS Destekli Navigasyon Sistemi. Doktora Tezi, Selçuk Üniversitesi, Fen Bilimleri Enstitüsü, Konya.
- Cressie, N.A.C. (1993). Statistics for Spatial Data. John Wiley and Sons Inc., New York, NY.
- Cybenko, G. (1989). Approximations by superpositions of sigmoidal functions. *Mathematics of Control, Signals and Systems*, **2**: 303-314.
- D'Anastasio, E., De Martini, P.M., Selvaggi, G., Pantosti, D., Marchioni, A. and Maseroli, R. (2006). Short-term vertical velocity field in the Apennines (Italy) revealed by geodetic levelling data. *Tectonophysics*, **418**, 219-234.
- DARPA (1988). Neural Network Study, AFCEA International Press, Fairfax, VA.
- Delacou, B., Sue, C., Nocquet, J.M., Champagnac, J.D., Allanic, C. and Burkhard, M. (2008). Quantification of strain rate in the Western Alps using geodesy: Comparisons with seismotectonics. *Swiss Journal of Geosciences*, **101**: 377-385.
- Demir C. ve Açıkgöz M. (2000). Türkiye Ulusal Temel GPS Ağı noktalarındaki uzun periyotlu koordinat değişimlerinin (seküler hızlarının) kestirilmesi. *Harita Dergisi*, **123**: 1-16.
- Deniz, İ. and Özener, H. (2008). Determination of velocity field and strain accumulation of densification network in Marmara region. Integrating Generations, FIG Working Week, 14-19 June 2008, Stockholm, Sweden.
- Efe, M.Ö. ve Kaynak, O. (2004). Yapay Sinir Ağları ve Uygulamaları. Boğaziçi Üniversitesi Yayınları, İstanbul.
- Elmas, Ç. (2003). Yapay Sinir Ağları. Seçkin Yayıncılık, Ankara.

- Erdoğan, S., Şahin, M., Tiryakioğlu, İ., Güllü, E. and Telli, A.K. (2009). GPS velocity and strain rate fields in southwest Anatolia from repeated GPS measurements. *Sensors*, **9**: 2017-2034.
- Erdoğan, S. (2010). Modelling the spatial distribution of DEM error with geographically weighted regression: An experimental study. *Computers and Geosciences*, **36**: 34-43.
- Fausett, L. (1999). Fundamentals of Neural Networks: Architectures, Algorithms and Applications. Prentice Hall, Upper Saddle River, NJ.
- Fukushima, K. (1980). Neocognitron: A self organizing neural network model for a mechanism of pattern recognition unaffected by shift in position. *Biological Cybernetics*, **36-4**: 193-202.
- Funahashi, K. (1989). On the approximate realization of continuous mappings by neural networks. *Neural Networks*, **2**: 183-192.
- Graupe, D. (2007). Principles of Artificial Neural Networks. World Scientific Publishing, Singapore.
- Grossberg, S. (1976). Adaptive pattern classification and universal recording: I. Parallel development and coding of neural feature detectors. *Biological Cybernetics*, **23**: 121-134.
- Grossberg, S., Carpenter, G.A. and Reynolds, J.H. (1995). A fuzzy ARTMAP nonparametric probability estimator for nonstationary pattern recognition problems. *IEEE Transaction on Neural Networks*, **6**: 1330-1336.
- Güllü, M. and Yılmaz, İ. (2010). Outlier detection for geodetic nets using ADALINE learning algorithm. *Scientific Research and Essays*, **5-5**: 440-447.
- Güllü, M., Yılmaz, İ., Yılmaz, M. and Turgut, B. (2011a). An alternative method for estimating densification point velocity based on back propagation artificial neural networks. *Studia Geophysica et Geodaetica*, **55**: 73-86.
- Güllü, M., Yılmaz, M. and Yılmaz, İ. (2011b). Application of back propagation artificial neural network for modelling local GPS/Levelling geoid undulations:

A comparative study. Bridging the Gap between Cultures, FIG Working Week, 18-22 May 2011, Marrakech, Morocco.

Güllü, M., Yılmaz M., Yılmaz, İ. And Turgut B. (2011c). Datum transformation by artificial neural networks for geographic information systems applications. In: Ayvaz M. (Ed.), Proceedings of the International Symposium on Environmental Protection and Planning: Geographic Information Systems and Remote Sensing Applications, Izmir, Turkey, 13-19.

Hackl, M., Malservisi, R. And Wdowinski, S. (2009). Strain rate patterns from dense GPS networks. *Natural Hazards and Earth System Sciences*, **9**: 1177-1187.

Han, M., Zhu, X. and Yao, W. (2012). Remote sensing image classification based on neural network ensemble algorithm. *Neurocomputing*, **78**: 133-138.

Haykin, S. (1999). Neural Networks: A Comprehensive Foundation. Prentice Hall, Upper Saddle River, NJ.

Hebb, D.O. (1949). The Organization of Behavior. John Wiley & Sons, New York, NY.

Helmert, F.R. (1880). Die Mathematischen und Physikalischen Theorieen der Höheren Geodäsie. Druck und Verlag von B.G. Teubner, Leipzig.

Heine, K. (2008). Fuzzy technology and ANN for analysis of deformation processes. In: Reiterer, A. and Egly, U. (Eds.), Proceedings of the 1st International Workshop on Application of Artificial Intelligence in Engineering Geodesy, Wien, Austria, 9-25.

Hinton, G.E. and Sejnowski, T.J. (1986). Learning and relearning in Boltzmann machines. In: Rumelhart, D.E. and McClelland, J.L. (Eds.), Distributed Processing, Explorations in the Microstructure of Cognition, MIT Press, Cambridge, MA.

HKMO (2008). Açıklamalı Örnekleme Büyük Ölçekli Harita ve Harita Bilgileri Üretim Yönetmeliği. İşkur Matbaacılık, Ankara.

Hochreiter, S. and Schmidhuber, J. (1997). Long short-term memory. *Neural Computation*, **9**: 1735-1780.

- Hopfield, J.J. (1982). Neural networks and physical systems with emergent collective computational abilities. *Proceedings of the National Academy of Sciences*, **79**: 2554-2558.
- Hornik, K., Stinchcombe, M. and White, H. (1989). Multilayer feedforward networks are universal approximators. *Neural Networks*, **2-5**: 359-366.
- Isaaks, E.H. and Srivastava, R.M. (1989). An Introduction to Applied Geostatistics. Oxford University Press, New York, NY.
- İnal, C. ve Yiğit, C.Ö. (2003). Jeodezik uygulamalarda kriging enterpolasyon yönteminin kullanılabilirliği. TUJK 2003 Yılı Bilimsel Toplantısı, Coğrafi Bilgi Sistemleri ve Jeodezik Ağlar Çalıştayı, 24-26 Eylül 2003, Konya, 177-185.
- Joseph, V.R. (2006). Limit Kriging. *Technometrics*, **48-4**: 458-466.
- Junjie, W., Huiying, G. and Junfeng, X. (2010). Application of artificial neural networks and GIS in urban earthquake disaster mitigation. Proceedings of the International Conference on Intelligent Computation Technology and Automation, 726-729.
- Kaftan, İ. (2010). Batı Türkiye Gravite ve Deprem Katalog Verilerinin Yapay Sinir Ağları ile Değerlendirilmesi. Doktora Tezi, Dokuz Eylül Üniversitesi, Fen Bilimleri Enstitüsü, İzmir.
- Kavzoğlu, T. and Saka, M.H. (2005). Modelling local GPS/levelling geoid undulations using artificial neural networks. *Journal of Geodesy*, **78**: 520-527.
- Kavzoğlu, T. (2009). Increasing the accuracy of neural network classification using refined training data. *Environmental Modelling and Software*, **24**: 850-858.
- Kohonen, T. (1972). Correlation matrix memories. *IEEE Transaction on Computers*, **C21-4**: 353-359.
- Kohonen, T. (1984). Self-Organization and Associative Memory. Springer, Berlin.
- Krige, D.G. (1951). A statistical approach to some basic mine valuation problems on the Witwatersrand. *Journal of the Chemical, Metallurgical and Mining Society of South Africa*, **52-6**: 119-139.

- Kurt, A.İ. ve Deniz, R. (2010). Deformasyon hızlarının iyileştirilmesinde sabit GPS istasyonları zaman serileri analizinden yararlanılması. *Harita Dergisi*, **144**: 20-28.
- Lee, T.T. and Jeng J.T. (1998). The Chebyshev-Polynomials-Based unified model neural networks for function approximation. *IEEE Transactions on Systems, Man, and Cybernetics-Part B: Cybernetics*, **28-6**: 925-935.
- Lei, Q., Lei, L. and Zemin W. (2010). An tropospheric delay model for GPS net RTK. Proceedings of the 2nd International Conference on Information Technology and Computer Science, 98-101.
- Liao, D., Wang, Q., Zhou Y., Liao, X. and Huang, C. (2012). Long-term prediction of the Earth orientation parameters by the artificial neural network technique. *Journal of Geodynamics*, (in press), **Doi**:10.1016/j.jog.2011.12.004.
- Lin, L.S. and Wang, Y.J. (2006). A study on cadastral coordinate transformation using artificial neural network. Proceedings of the 27th Asian Conference on Remote Sensing, Ulaanbaatar, Mongolia.
- Lin, L.S. (2007). Application of a back-propagation artificial neural network to regional grid-based geoid model generation using GPS and leveling data. *Journal of Surveying Engineering*, **133**: 81-89.
- Lippmann, R.P. (1987). An introduction to computing with neural nets. *IEEE ASSP Magazine*, **4**: 4-22.
- Liu, C., Zhang, L., Craig, J.D., Solomon D.S., Brann, T.B. and Lawrence, E.C. (2003). Comparison of neural networks and statistical methods in classification of ecological habitats using FIA data. *Forest Science*, **49-4**: 619-631.
- MacKay, D.J.C. (2004). Information Theory, Inference, and Learning Algorithms. Cambridge University Press, Cambridge.
- Matheron, G. (1963). Principles of geostatistics. *Economic Geology*, **58**: 1246-1266.
- 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, M., Reilinger, R., Sanli, I., Seeger, H., Tealeb, A., Toksöz, M.N. and Veis, G. (2000). GPS constraints on crustal movements and deformations in the Eastern Mediterranean (1988-1997): Implications for plate dynamics. *Journal of Geophysical Research*, **105-B3**: 5695-5719.
- McCulloch, W.S. and Pitts, W.H. (1943). A logical calculus of the ideas immanent in nervous activity. *Bulletin of Mathematical Biophysics*, **5**: 115-133.
- Miima, J.B. (2002). Artificial Neural Networks and Fuzzy Logic Techniques for the Reconstruction of Structural Deformations. PhD Thesis, Institute for Geodesy and Photogrammetry, University of Technology, Braunschweig.
- Miima, J.B. and Niemeier, W. (2004). Adapting neural networks for modelling structural behavior in geodetic deformation monitoring. *ZfV*, **3**: 1-8.
- Minsky, M. and Papert, S. (1969). Perceptrons. MIT Press, Cambridge, MA.
- Moghtased-Azar, K. and Zaletnyik, P. (2009). Crustal velocity field modelling with neural network and polynomials. In: Sideris, M.G. (Ed.), Observing our Changing Earth. International Association of Geodesy Symposia, **133**: 809-816.
- Moody, J. and Darken, C. (1989). Fast learning in networks of locally-tuned processing units. *Neural Computation*, **1**: 281-294.
- Nabiyev, V.V. (2010). Yapay Zeka Problemler-Yöntemler-Algoritmalar. Seçkin Yayıncılık, Ankara.
- Neuner, H. (2010). Modelling deformations of a lock by means of artificial neural Networks. In: Reiterer, A., Egly, U., Heinert, M. and Riedel, B. (Eds.), Proceedings of the 2nd International Workshop on Application of Artificial Intelligence in Engineering Geodesy, Braunschweig, Germany, 32-41.
- Nocquet, J.M. and Calais, E. (2003). Crustal velocity field of western Europe from permanent GPS array solutions, 1996-2001. *Geophysical Journal International*, **154**: 72-88.
- Novotny, Z. and Kostecky, J. (2008). The estimated annual velocities of EUREF-EPN stations located in Central European region. *Geophysical Research Abstracts*, **10**: EGU2008-A-02183.

- Ornthammarath, T. Corigliano, M. and Lai, C.G. (2008). Artificial neural networks applied to the seismic design of deep tunnels. Proceedings of the 14th World Conference on Earthquake Engineering, 12-17 October 2008, Beijing, China.
- Özaydın, Ö. (2009). Porsuk Barajı Su Seviyesinin Öngörülerinin Elde Edilmesinde Yapay Sinir Ağları ve ARMAX Modellerinin Karşılaştırmalı İncelenmesi. Doktora Tezi, Eskişehir Osmangazi Üniversitesi, Fen Bilimleri Enstitüsü, Eskişehir.
- Öztemel, E. (2006). Yapay Sinir Ağları. Papatya Yayıncılık, İstanbul.
- Panchal, G., Ganatra, A., Kosta, Y.P. and Panchal, D. (2011) Behaviour analysis of multilayer perceptrons with multiple hidden neurons and hidden layers. *International Journal of Computer Theory and Engineering*, **3-2**: 332-337.
- Patan, K. (2008). Artificial Neural Networks for the Modelling and Fault Diagnosis of Technical Processes. Springer, London-New York.
- Perez-Ortiz, J.A., Gers, F.A., Eck, D. and Schmidhuber, J. (2003). Kalman filters improve LSTM network performance in problems unsolvable by traditional recurrent nets. *Neural Networks*, **16-2**: 241-250.
- Peterson, S. and Flanagan, A.B. (2009). Neural network hedonic pricing models in mass real estate appraisal. *Journal of Real Estate Research*, **31-2**: 147-164.
- Poggio, T. and Girosi, F., 1990. Regularization algorithms for learning that are equivalent to multilayer Networks. *Science*, **224**: 978-982.
- Poulton, M.M. (2001). Computational Neural Networks for Geophysical Data Processing (Handbook of Geophysical Exploration: Seismic Exploration). Pergamon, London-New York.
- Powell, M.J.D. (1987). Radial basis functions for multivariable interpolation: A review. In: Mason, J.C. and Cox, M.G. (Eds.), Algorithms for Approximation, Clarendon Press, Oxford.
- Riedel, B. and Heinert, M. (2008). An adapted support vector machine for velocity field interpolation at the Baota landslide. In: Reiterer, A. and Egly, U. (Eds.),

- Proceedings of the 1st International Workshop on Application of Artificial Intelligence in Engineering Geodesy, Wien, Austria, 101-115.
- Rosenblatt, F. (1958). The perceptron: A probabilistic model for information storage and organization in the brain. *Psychological Review*, **65-6**: 386-408.
- Rumelhart, D.E. and McClelland, J.L. (1986). *Parallel Distributed Processing, Explorations in the Microstructure of Cognition. Volume 1: Foundations*. MIT Press, Cambridge, MA.
- Rumelhart, D.E., Hinton, G.E. and Williams, R.J. (1986). Learning representation by backpropagating errors. *Nature*, **323-9**: 533-536.
- Sağıroğlu, Ş., Beşdok, E. ve Erler, M. (2003). *Mühendislikte Yapay Zeka Uygulamaları-I: Yapay Sinir Ağları*. Ufuk Yayıncılık, Kayseri.
- Sarle, W.S. (1994). Neural networks and statistical models. Proceedings of the 19th Annual SAS Users Group International Conference, 1538-1550.
- Schroeder, M., Cornford, D. and Nabney, I.T. (2009). Data Visualisation and Exploration with Prior Knowledge. In: Palmer-Brown, D., Draganova, C., Pimenidis, E. and Mouratidis, H. (Eds.), *Engineering Applications of Neural Networks*. Springer, Berlin.
- Schuh, H., Ulrich, M., Egger, D., Muller, J. and Schwegmann, W. (2002). Prediction of Earth orientation parameters by artificial neural networks. *Journal of Geodesy*, **76**: 247-258.
- Specht, D. (1990). Probabilistic neural networks. *Neural Networks*, **3**: 110-118.
- Specht, D. (1991). A generalized regression neural network. *IEEE Transactions on Neural Networks*, **2**: 568-576.
- Sutton, R. S. and Barto, A.G. (1998). *Reinforcement Learning: An Introduction*. MIT Press, Cambridge, MA.
- Şen, Z. (2004). *Yapay Sinir Ağı İlkeleri*. Su Vakfı Yayınları, İstanbul.
- Tierra A., Dalazoana R. and De Freitas S. (2008). Using an artificial neural network to improve the transformation of coordinates between classical geodetic reference frames. *Computers and Geosciences*, **34**: 181-189

- Tobler, W.R. (1970). A computer movie simulating urban growth in the Detroit region. *Economic Geography*, **46-2**: 234-24.
- Torge, W. (2001). Geodesy. Walter de Gruyter, 3rd edition, Berlin-New York.
- Tosunoğlu, N.G. (2007). Mekansal İstatistikte Bulanık Uyarlamalı Ağ Yaklaşımı ile Depremi oluşturan Yerkabuğu Hareket Hızlarının Kestirimi. Doktora Tezi, Ankara Üniversitesi, Fen Bilimleri Enstitüsü, Ankara.
- Üstün, A. (2006). Fiziksel Jeodezi Lisans Ders Notları (yayımlanmadı). Konya.
- Veronez, M.R., Thum, A.B. and Souza, G.C. (2006). A new method for obtaining geoidal undulations through artificial neural networks. Proceedings of 7th International Symposium on Spatial Accuracy Assessment in Natural Resources and Environmental Sciences, Lisbon, Portugal.
- Werbos, P.J. (1974). Beyond Regression: New Tools for Prediction and Analysis in the Behavioral Sciences. PhD Thesis, Applied Mathematics, Harvard University, Boston, MA.
- Widrow, B. and Hoff, M.E. (1960). Adaptive switching circuits. *IRE WESCON Convention Record*, **4**: 96-104.
- Wolfram Research (2005). Mathematica Neural Networks: Train and Analyze Neural Networks to Fit Your Data. Wolfram Research Inc., Champaign, IL.
- Wright, T. and Wang, H. (2010). Large-scale crustal velocity field of western Tibet from InSAR and GPS reveals internal deformation of the Tibetan plateau. *Geophysical Research Abstracts*, **12**: EGU2010-7092.
- Yaprak, S. (2007). Kriging Yönteminin Geoit Yüzeyi Modellemesinde Kullanılabilirliğinin Araştırılması ve Varolan Yöntemlerle Karşılaştırılması. Doktora Tezi, İstanbul Teknik Üniversitesi, Fen Bilimleri Enstitüsü, İstanbul.
- Yeung, D.S., Cloete, I., Shi, D. and Wing W.Y. (2010). Sensitivity Analysis for Neural Networks. Springer, London-New York.
- Yılmaz, İ. and Güllü, M. (2010). Georeferencing of historical maps using back propagation artificial neural network. *Experimental Techniques*, (in press), **Doi**: 10.1111/j.1747-1567.2010.00694.x

- Yılmaz, İ., Güllü, M., Yılmaz, M. and Dereli, M.A. (2010). Compass roses on the Book of Navigation (Kitab-ı Bahriye): Declination data source for geomagnetic field models. *Physics of the Earth and Planetary Interiors*, **182**: 170-174.
- Yılmaz, M. ve Güllü, M. (2011). Jeodezik koordinat dönüşümünde yapay sinir ağları uygulaması. 13. Türkiye Harita Bilimsel ve Teknik Kurultayı, 18-22 Nisan 2011, Ankara.
- Yurtoğlu, H. (2005). Yapay Sinir Ağları ile Öngörü Modellemesi: Bazı Makroekonomik Değişkenler İçin Türkiye Örneği. Uzmanlık Tezi, Devlet Planlama Teşkilatı, Ankara.
- Zhang, G.P. (2004). Business forecasting with artificial neural networks: An overview. In: Zhang, G.P. (Ed.), *Neural Networks in Business Forecasting*, Idea Group Publishing, London.
- Zurada, J.M. (1992). *Introduction to Artificial Neural Systems*. West Publishing Company, St. Paul, MN.

İnternet Kaynakları

Erişim Tarihi

1. http://www.optimaltrader.net/neural_network.htm

01.05.2012

ÖZGEÇMİŞ

Adı Soyadı : Mustafa YILMAZ
Doğum Yeri ve Tarihi : Sarayönü (Konya) – 21/01/1977
Yabancı Dili : İngilizce (ÜDS: 82.500)
İletişim (E-posta) : mustafayilmaz@aku.edu.tr

Eğitim Durumu (Kurum ve Yıl)

Lise : Meram Anadolu Lisesi (Konya) 1992-1995
Lisans : Selçuk Üniversitesi, Mühendislik Mimarlık Fakültesi,
Jeodezi ve Fotogrametri Mühendisliği (Konya) 1995-1999
Yüksek Lisans : Selçuk Üniversitesi, Fen Bilimleri Enstitüsü,
Jeodezi ve Fotogrametri Mühendisliği (Konya) 1999-2002

Çalıştığı Kurumlar ve Yıl : TEDAŞ Genel Müdürlüğü (Ankara) 2000-2008
Osmangazi EDAŞ (Afyonkarahisar) 2008-2010
Afyon Kocatepe Üniversitesi (Afyonkarahisar) 2010-

Yayınları (SCI ve diğer) :

Yılmaz, İ., Yılmaz, M., Güllü, M. and Turgut, B. (2010). Evaluation of recent global geopotential models based on GPS/levelling data over Afyonkarahisar (Turkey). *Scientific Research and Essays*, **5-5**: 484-493.

Yılmaz, İ., Güllü, M., Yılmaz, M. and Dereli, M.A. (2010). Compass roses on the Book of Navigation (Kitab-ı Bahriye): Declination data source for geomagnetic field models. *Physics of the Earth and Planetary Interiors*, **182**: 170-174.

Güllü, M., Yılmaz, İ., Yılmaz, M. and Turgut, B. (2011). An alternative method for estimating densification point velocity based on back propagation artificial neural networks. *Studia Geophysica et Geodaetica*, **55**: 73-86.

Yılmaz, M. ve Güllü, M. (2011). Jeodezik koordinat dönüşümünde yapay sinir ağları uygulaması. 13. Türkiye Harita Bilimsel ve Teknik Kurultayı, 18-22 Nisan 2011, Ankara.

- Güllü, M., Yılmaz, M. and Yılmaz, İ. (2011). Application of back propagation artificial neural network for modelling local GPS/Levelling geoid undulations: A comparative study. Bridging the Gap between Cultures, FIG Working Week, 18-22 May 2011, Marrakech, Morocco.
- Güllü, M., Yılmaz M., Yılmaz, İ. And Turgut B. (2011). Datum transformation by artificial neural networks for geographic information systems applications. In: Ayvaz M. (Ed.), Proceedings of the International Symposium on Environmental Protection and Planning: Geographic Information Systems and Remote Sensing Applications, Izmir, Turkey, 13-19.