

**LOKAL JEOİT BELİRLEMEDE
YAPAY SİNİR AĞLARI VE KRİGİNG
YÖNTEMLERİNİN KARŞILAŞTIRILMASI
YÜKSEK LİSANS TEZİ**

Eray AŞIK

DANIŞMAN

Doç.Dr. Mevlüt GÜLLÜ

JEODEZİ VE FOTOGRAMETRİ MÜHENDİSLİĞİ

Haziran, 2013

Bu tez çalışması 12.FEN.BİL.27 numaralı proje ile Afyon Kocatepe Üniversitesi
Bilimsel Araştırma Projeleri Koordinasyon Birimi tarafından desteklenmiştir.

AFYON KOCATEPE ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

YÜKSEK LİSANS TEZİ

**LOKAL JEOİT BELİRLEMEDE YAPAY SİNİR AĞLARI VE
KRİGİNG YÖNTEMLERİNİN KARŞILAŞTIRILMASI**

Eray AŞIK

DANIŞMAN

Doç.Dr. Mevlüt GÜLLÜ

JEODEZİ VE FOTOGRAMETRİ MÜHENDİSLİĞİ

Haziran, 2013

TEZ ONAY SAYFASI

Eray AŐIK tarafından hazırlanan ‘‘Lokal Jeoit Belirlemede Yapay Sinir Ağları ve Kriging Yöntemlerinin Karşılaştırılması’’ adlı tez çalışması lisansüstü eğitim ve öğretim yönetmeliğinin ilgili maddeleri uyarınca 24/06/2013 tarihinde aŐağıdaki jüri tarafından oy birliğı/oy çokluğı ile Afyon Kocatepe Üniversitesi Fen Bilimleri Enstitüsü Jeodezi ve Fotogrametri Mühendisliğı **Anabilim Dalı’nda YÜKSEK LİSANS TEZİ** olarak kabul edilmiştir.

Danışman	: Doç.Dr. Mevlüt GÜLLÜ	
Başkan	: Doç. Dr. Mevlüt GÜLLÜ	İmza
	Afyonkocatepe Üni. Müh. Fakültesi,	
Üye	: Doç. Dr. İbrahim YILMAZ	İmza
	Afyonkocatepe Üni. Müh. Fakültesi,	
Üye	: Doç. Dr. Ekrem TUŐAT	İmza
	Selçuk Üni. Çumra Meslek Yüksekokulu,	

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

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

BİLİMSEL ETİK BİLDİRİM SAYFASI
Afyon Kocatepe Üniversitesi

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

- 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,
- Ve bu tezin herhangi bir bölümünü bu üniversite veya başka bir üniversitede başka bir tez çalışması olarak sunmadığımı

beyan ederim.

14/06/2013

Eray AŞIK

ÖZET

Yüksek Lisans Tezi

LOKAL JEOİT BELİRLEMEDE YAPAY SİNİR AĞLARI VE KRİĞİNG YÖNTEMLERİNİN KARŞILAŞTIRILMASI

Eray AŞIK

Afyon Kocatepe Üniversitesi

Fen Bilimleri Enstitüsü

Jeodezi ve Fotogrametri Mühendisliği Anabilim Dalı

Danışman: Doç. Dr. Mevlüt GÜLLÜ

Son yıllarda konumlama teknolojilerinin artmasıyla birlikte GPS (Küresel Konum Belirleme Sistemi), jeodezik ölçümlerde yaygın olarak kullanılmaktadır. Mühendislik uygulamalarında GPS ölçümlerinin yatay koordinat değerleri rahatlıkla kullanılabilirken düşey koordinat değerlerinin dönüştürülmesi gerekmektedir. Bu dönüşüm işlemini gerçekleştirmek için Büyük Ölçekli Harita ve Harita Bilgileri Üretim Yönetmeliğinde (BÖHHBÜY), uygulanacak ölçü ve hesaplama yöntemleriyle ilgili çeşitli öneriler sunulmaktadır. Yerel bir alanda ortometrik yüksekliği bilinen noktalarda GPS ölçülerinden yararlanarak jeoit modelinin hesaplanması ve sonrasında yükseklik dönüşüm problemi çözümünün sağlanması önerilen yaklaşımlardan biridir. GPS ölçümlerinden elde edilen elipsoidal yüksekliklerin mühendislik uygulamalarında kullanılan ortometrik yüksekliklere dönüştürülebilmesi için ölçümü yapılan noktanın jeoit yüksekliğinin bilinmesi gerekir. Gerçekleştirilen bu çalışmada Afyonkarahisar ve çevre illerde bulunan 86 adet jeoit yüksekliği bilinen TUTGA noktası kullanılmıştır. Yaklaşık 360x340 km²'lik bir alana yayılmış bu 86 adet TUTGA noktalarından 3 adet uygun dağılımlı veri grubu oluşturulmuştur. Her bir veri grubunda farklı sayıda referans ve test noktaları bulunmaktadır. Bu veri gruplarında referans noktaları dayanak alınmıştır. Günümüzde mühendislik alanında sıkça kullanılan ve başarısını kanıtlamış bir enterpolasyon yöntemi olan, Kriging yöntemiyle test noktalarının jeoit yükseklikleri hesaplanmıştır. Daha sonra aynı test noktaları Yapay Sinir Ağları (YSA) yöntemiyle

hesaplanmıřtır. Her iki yntemle elde edilen karesel ortalama hata deęerleri birbiriyle karřılařtırılarak YSA ynteminin lokal jeoit yzeyi modellemesi probleminde kullanılabilirlięi arařtırılmıřtır.

2013, xii+ 71 sayfa

Anahtar Kelimeler: TUTGA, Jeoit Ykseklieęi, Yapay Sinir Aęları, Kriging Enterpolasyon Yntemi

ABSTRACT

M.Sc Thesis

COMPARISON OF ARTIFICIAL NEURAL NETWORK AND KRIGING METHODS IN LOCAL GEOID MODELLING

Eray AŞIK

Afyon Kocatepe University

Graduate School of Natural and Applied Sciences

Department of Geodesy and Photogrammetry Engineering

Supervisor: Assoc. Prof. Mevlüt Güllü

In recent years, GPS (Global Positioning System) is widely used in geodetic measurements by the development of satellite positioning technologies. In engineering applications, vertical coordinate values of GPS measurements must be transformed while the horizontal coordinates values can be easily used. Several suggestions about measure and calculation methods for to evaluate the transformation which will be applied are presented in Large Scale Map and Map Information Production Regulation. To calculation of geoid model by utilizing the GPS measurements in orthometric height known points in a local area and then to provide the solution of the height transformation problem is one of the proposed approach. Geoid height of measurement points need to be known for transformation of ellipsoidal heights derived from GPS measurements to orthometric heights. In this study, 86 geoid height known TUTGA points in Afyonkarahisar and around cities are used. Three appropriate distribution of data are created from these TUTGA points over an area of 360x340 km². There are different number of reference and test points in each data group. The reference points are taken as a basis in these data groups. The geoid heights of the test points are calculated with Kriging method which is widely used in engineering field and a succesfully interpolation method. And then same test points are calculated with

Artificial Neural Network (ANN). Root Mean Square Error (RMSE) values derived from both method are compared and the availability of ANN in determination of local geoid surface model is investigated.

2013, xii + 71 pages

Key Words: TUTGA, Geoid Height, Artificial Neural Network, Kriging Interpolation Method

TEŐEKKÜR

Bu arařtırmanın konusu, deneysel alıřmaların ynlendirilmesi, sonuların deęerlendirilmesi ve yazımı ařamasında yapmıř olduęu byk katkılarından dolayı tez danıřmanım Sayın Do. Dr. Mevlt GLL'ye, arařtırma ve yazım sresince yardımlarını esirgemeyen Sayın Dr. Mustafa YILMAZ'a ve Yk. Elk. Mh. Emre AKARSLAN'a, her konuda neri ve eleřtirileriyle yardımlarını grdęm hocalarıma ve arkadařlarıma teőekkr ederim.

Hayatımın her ařamasında bana maddi ve manevi desteklerinden dolayı aileme teőekkr ederim.

Eray AŐIK

AFYONKARAHİSAR, 2013

İÇİNDEKİLER DİZİNİ

Sayfa

ÖZET	i
ABSTRACT	iii
TEŞEKKÜR	v
İÇİNDEKİLER DİZİNİ.....	vi
SİMGELER ve KISALTMALAR DİZİNİ	viii
ŞEKİLLER DİZİNİ	ix
ÇİZELGELER DİZİNİ.....	xii
1. GİRİŞ	1
2. LİTERATÜR BİLGİLERİ	6
2.1. Jeoit Yüzeyi Modellemede Kullanılan Yöntemler	6
2.1.1 Polinomal Yöntemler	6
2.1.2 Multikvadrik Enterpolasyon Yöntemi	6
2.1.3 Ağırlıklı Ortalama İle Enterpolasyon Yöntemi	6
2.1.4 Sonlu Elemanlar Yöntemi.....	6
2.1.5 Kollokasyon Yöntemi	7
2.1.6 Bulanık Çıkarım Sistemleri	7
2.1.7 Radyal Tabanlı Fonksiyonlar ile Yüzey Modelleme Yöntemi	7
2.2 Kriging Enterpolasyon Yöntemi	8
2.3 Yapay Sinir Ağları	14
2.3.1 Biyolojik Sinir Sistemi	14
2.3.2 Biyolojik Sinir Hücresinin Yapısı	14
2.3.3 Yapay Sinir Ağı Tanımı.....	15
2.3.4 Yapay Nöron.....	17
2.3.5 Yapay Sinir Ağlarının Yapısı	20
2.3.6 Yapay Sinir Ağlarının Sınıflandırılması	22
2.3.6.1 Bağlantı Yapılarına Göre Yapay Sinir Ağları.....	22
a. İleri Beslemeli Yapay Sinir Ağları	22
b. Geri Beslemeli Yapay Sinir Ağları	23
2.3.6.2 Öğrenme Algoritmalarına Göre Yapay Sinir Ağları.....	24
a. Danışmanlı Öğrenme	25
b. Danışmansız Öğrenme	26

c. Takviyeli Öğrenme	26
2.3.7 Yapay Sinir Ağlarında Temel Öğrenme Kuralları.....	27
2.3.8 Geri Yayılımlı Yapay Sinir Ağı.....	28
2.3.8.1 Geri Yayılım Algoritması	29
2.3.9 Yapay Sinir Ağlarının Üstünlükleri ve Sınırlamaları	39
2.3.10 Yapay Sinir Ağlarının Kullanım Alanları.....	42
2.3.10.1 Yapay Sinir Ağlarının Harita Mühendisliğindeki Kullanım Alanları	43
3. MATERYAL VE METOD	44
3.1. Çalışma Alanı ve Veri Seti	44
3.2. Uygulamanın Amacı	45
3.3. Uygulama Metodolojisi	45
4. BULGULAR VE SONUÇLAR	53
5. KAYNAKLAR	60
ÖZGEÇMİŞ.....	71

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
Δh	Yükseklik farkı
y'	İstenilen çıktı değeri
α	Momentum katsayısı
η	Öğrenme oranı
T	Toplama fonksiyonu

Kısaltmalar

BÖHHBÜY	Büyük Ölçekli Harita ve Harita Bilgileri Üretim Yönetmeliği
ÇKA	Çok katmanlı algılayıcı
GYSA	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
ADALINE	Uyarlamalı Doğrusal Nöron (Adaptive Linear Neuron)
TUTGA	Türkiye Ulusal Temel GPS Ağı
TUYKA	Türkiye Ulusal Yatay Kontrol Ağı
ITRF	Uluslararası Yersel Referans Sistemi
RTF	Radyal Tabanlı Fonksiyon

ŞEKİLLER DİZİNİ

	Sayfa
Şekil 1.1 TUTGA noktalarının coğrafi dağılımı (Ayhan vd. 2002).....	2
Şekil 1.2 Elipsoidal yükseklik ile ortometrik yükseklik arasındaki ilişki (URL-1,2011)	4
Şekil 2.1 Kriging kestirimi	9
Şekil 2.2 Biyolojik Sinir Hücresi	14
Şekil 2.3 Yapay nöronun bileşenleri (Kaftan 2010).....	17
Şekil 2.4 Aktivasyon fonksiyonlarının grafikleri (Yılmaz 2012)	20
Şekil 2.5 Çok katmanlı yapay sinir ağlarının genel yapısı (Yılmaz 2012)	21
Şekil 2.6 Tek katmanlı yapay sinir ağları (Yılmaz 2012)	21
Şekil 2.7 İleri beslemeli yapay sinir ağları (Yılmaz 2012)	23
Şekil 2.8 Geri beslemeli yapay sinir ağları (Yılmaz 2012)	24
Şekil 2.9 Danışmanlı öğrenme yapısı (Yılmaz 2012)	25
Şekil 2.10 Danışmansız öğrenme yapısı (Yılmaz 2012)	26
Şekil 2.11 Takviyeli öğrenme yapısı (Yılmaz 2012)	27
Şekil 2.12 Geri yayımlı yapay sinir ağı (Yılmaz 2012)	29
Şekil 2.13 Gizli katmandaki nöron sayısına göre eğitim ve test setlerinin hata eğrileri (Yılmaz 2012).....	34
Şekil 2.14 Öğrenme sürecini sonlandırma aralığı (Yılmaz 2012).....	37
Şekil 2.15 Geri yayılım algoritması için akış diyagramı (Yılmaz 2012)	38
Şekil 3.1 Türkiye Hibrit Jeoid Modeli-2009 (URL-2)	44
Şekil 3.2 Çalışma alanı ve jeodezik noktaların coğrafi dağılımı.....	45

Şekil 3.3 1 no'lu jeodezik ağ modeli (▲ → Referans; ● → Test)	46
Şekil 3.4 2 no'lu jeodezik ağ modeli (▲ → Referans; ● → Test)	47
Şekil 3.5 3 no'lu jeodezik ağ modeli (▲ → Referans; ● → Test)	47
Şekil 3.6 1. Veriseti test noktaları jeoit yüksekliği yüzey modeli (— HGK değeri, — Kriging hesap değeri)	49
Şekil 3.7 1. Veriseti test noktaları jeoit yüksekliği yüzey modeli (— HGK değeri, — YSA hesap değeri).....	49
Şekil 3.8 2. veriseti test noktaları jeoit yüksekliği yüzey modeli (— HGK değeri, — Kriging hesap değeri)	50
Şekil 3.9 2. veriseti test noktaları jeoit yüksekliği yüzey modeli (— HGK değeri, — YSA hesap değeri).....	50
Şekil 3.10 3. veriseti test noktaları jeoit yüksekliği yüzey modeli (— HGK değeri, — Kriging hesap değeri)	51
Şekil 3.11 3. veriseti test noktaları jeoit yüksekliği yüzey modeli (— HGK değeri, — YSA hesap değeri).....	51
Şekil 4.1 1. Model HGK yükseklik değerleri ile Kriging yöntemi arasındaki yükseklik fark haritası	54
Şekil 4.2 1. Model HGK yükseklik değerleri ile YSA yöntemi arasındaki yükseklik fark haritası	54
Şekil 4.3 2. Model HGK yükseklik değerleri ile Kriging yöntemi arasındaki yükseklik fark haritası	55
Şekil 4.4 2. Model HGK yükseklik değerleri ile YSA yöntemi arasındaki yükseklik fark haritası	55

Şekil 4.5 3. Model HGK yükseklik değerleri ile Kriging yöntemi arasındaki yükseklik fark haritası.....	56
Şekil 4.6 3. Model HGK yükseklik değerleri ile YSA yöntemi arasındaki yükseklik fark haritası	56
Şekil 4.7 Hesaplanan yükseklik farklarının KOH değerleri.....	57

ÇİZELGELER DİZİNİ

	Sayfa
Çizelge 2.1 Aktivasyon fonksiyonlarının matematiksel yapıları	19
Çizelge 3.1 Oluşturulan jeodezik ağ modelleri	46
Çizelge 4.1 Hesaplanan yükseklik farklarının mutlak istatistiksel değerleri (m.).....	58

1. GİRİŞ

Hızla gelişen uydu teknolojileri mesleğimizde de aynı hızda gelişmekte ve yaygınlaşmaktadır. Uydular ile konum belirleme sistemlerinin, hava şartlarından bağımsız sürekli ölçüm yapabilmesi, noktalar arası görüş zorunluluğunun olmaması, üç boyutlu yüksek duyarlılıkta konum elde etme özellikleri yersel konum belirleme sistemlerine göre en belirgin avantajları olarak sıralanabilir. Uydular ile konum belirleme sistemleri zaman ve iş gücü açısından da yersel sistemlere avantaj sağlar.

Global Konum Belirleme Sistemi'nin (GPS) temelleri 1960'lı yıllarda askeri uygulamalarda kullanılan TRANSİT sisteme dayanır. Amacı uçak ya da diğer askeri araçların konumlarının belirlenmesidir. Daha sonraları sistem sivil kullanıma açılmış ve jeodezik konum belirleme amacıyla 1967 yılından bu yana yaygın olarak kullanılmıştır. Ülkemizde 1980'li yıllardan itibaren kullanılmaya başlanmış olup, günümüzde yaygın olarak kullanılmaktadır.

GPS, uygun donanıma sahip kullanıcılarına, herhangi bir zamanda, yeryüzünün 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 *vd.* 2011a).

GPS ile yatayda birkaç mm düzeyinde doğruluk elde etmek mümkünken, düşeyde aynı durum söz konusu değildir. GPS tekniği, başlangıçta tamamen navigasyon amaçlı geliştirildiğinden yüksek doğrulukta konum ve yükseklik belirlemede etkin bir teknik olarak düşünülmemiştir (Park 1998).

GPS ile belirlenen yükseklik doğruluğunu kısıtlayan üç önemli etken vardır. Bunlar;


- Uydu konfigürasyonu ve geometrisi gibi sistem kaynaklı etkenler,
- GPS sinyallerinin atmosfer tabakalarından geçerken özellikle troposferde gecikmeye

uğraması ve bunun modellenemesinin güçlüğü (Blewitt 1993; Dodson 1995; Featherstone *et al.* 1998),

- GPS ölçmeleri ile elde edilen elipsoidal yüksekliklerin pratikte kullanılması için, hassas bir jeoit belirleme gerekliliğı (Yurt and Gökalp 2009) ve ortometrik yüksekliğe geçişteki hassasiyet kaybı; olarak sıralanabilir.

GPS'in üç boyutlu konum belirleme olanağını ülke genelinde etkin bir şekilde kullanmak ve ülkemizdeki tektonik plaka hareketleri ile depremler sonucu oluşan konum değışiklikleri nedeniyle güncel jeodezik gereksinimleri karşılamak amacıyla, HGK tarafından 1997 ve 1999 yılları arasında yapılan çalışmalarla Türkiye Ulusal Temel GPS Ağı (TUTGA) kurulmuştur.

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 bağı değışimleri ile uygun sistemde yüksekliği ve jeoit yüksekliği bilinen, nokta aralığı 25-50 km, jeoidin hızlı değışim gösterdiği bölgelerde 15 km olan, olabildiğince homojen dağılımlı 594 noktadan oluşan bir ağıdır (Ayhan *vd.* 2002).



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


Pratik uygulamalarda kullanılan ortometrik yükseklikler TUDKA-99'a baęlı olarak nivelman yöntemleriyle (geometrik, trigonometrik, vb.) belirlenmektedir. Ortometrik yükseklik sıfır yükseltili jeoit yüzeyinden itibaren çekül doğrutusu boyunca olan uzaklıktır. Nivelman ölçmeleri ile duyarlıęı iyi ortometrik yükseklikler elde edilirken, nivelmanın zaman alıcı ve işgücü gerektiren maliyeti yüksek bir yöntem olması, kullanıcıları modern yöntemlerle daha hızlı ve ekonomik şekilde hassas duyarlılıkta ortometrik yükseklik belirlemeye yönlendirmiştir.

Herhangi bir noktada GPS ile WGS-84 datumunda elde edilen elipsoidal yükseklięin ortometrik yükseklięe dönüştürülmesi için yeterli duyarlılıkta jeoit yükseklięinin bilinmesi gerekmektedir. Bu durumda yükseklik dönüşümünü sağlayacak jeoit modelinin belirlenmesine ihtiyaç duyulur.

Isı, basınç, yoğunluk, tuzluluk farkı, akıntı ve gelgit gibi etkilerden arındırılmış okyanus yüzeyiyle çakışıp karaların altında da devam ettięi düşünölen eşpotansiyelli yüzeye **jeoit** denmektedir (Yılmaz 2011). Jeoit, yükseklikler için sıfır yükseltili olarak kabul edilen başlangıç yüzeyidir ve yerin temel şekline verilen isimdir. Jeoidin matematiksel olarak gösterimi imkânsızdır ancak fiziksel olarak gösterilebildięinden dolayı jeodezinin temel yüzeyidir. Yerin biçim ve büyüklüğünü temsil eden jeoide; nokta yükseklikleri için başlangıç yüzeyinin tanımlanmasında, ortalama yer elipsoidinin belirlenmesinde, referans sistemlerinin yatay ve düşey datumunun belirlenmesinde, yerkabuęundaki ve deniz yüzeyindeki deęişimlerinin incelenmesinde, gravite deęişimlerinin belirlenmesinde ihtiyaç duyulmaktadır.

Jeoit modelleri gravite ölçöleriyle belirlenebileceęi gibi, belli bir alanda aynı noktalara ait GPS ve nivelman ölçölerinin gerçekleştirilmesiyle de belirlenebilir. Jeoit yüzeylerinin belirlenmesinde kullanılan ölçüm tekniklerinin hemen hemen tümü oldukça güç uygulanmakta, büyük ekonomik finansman gerektirmekte ve oldukça deneyimli bir ekip ile ölçömler gerçekleştirildięinden, ele alınan yüzey üzerinde yeteri kadar sıklıkta bu ölçömler yapılamamaktadır. Bununla birlikte fiziksel yeryüzündeki zorlu arazi koşullarından dolayı da her noktaya ölçömler uygulanamamaktadır. Bu nedenlerden dolayı arazi üzerinde homojen yayılmış yeteri kadar sıklıkta nokta üzerinde

elde edilmiş ölçüler ile modelleme yapılarak yüzey üzerinde sıklaştırma yapılmaktadır (Akçın 2001). Bu konuya yönelik pek çok araştırma literatürde mevcuttur (Akyılmaz 2005; Fotopoulos 2003; Kotsakis ve Sideris 1999; Kuhar *et al.* 2001; Kavzoğlu ve Saka 2005; Erol 2007; Yanalak ve Baykal 2001). Yapılan bu çalışmalar ile uygulama alanlarını temsil eden en iyi jeoit modelinin belirlenmesi amaçlanmıştır. Çünkü GPS ile bulunan elipsoidal yüksekliklerden elde edilen ortometrik yüksekliklerin hassasiyeti, elipsoidal yüksekliğin ve jeoit modelinin hassasiyeti ile ilişkilidir (Çakır 2012).



Şekil 1.2 Elipsoidal yükseklik ile ortometrik yükseklik arasındaki ilişki (URL-1 2011)

Yeryüzündeki herhangi bir noktadan başlangıç olarak kabul edilen sıfır yükseltili jeoit yüzeyine çekül doğrultusunda inilen dikin boyu o noktanın ortometrik yüksekliği olarak anlaşılmaktadır. Elipsoidal yükseklikler geometrik yükseklikler olup, pratik ölçme, mühendislik ve jeofizik uygulamalarında fiziksel bir anlamı yoktur (Featherstone 1998).

Jeoit modellemesi; Kiamehr ve Sjöberg (2005), Veronneau *et al.* (2006), Forsberg *et al.* (1992), Turgut *vd.* (2002), İnal (1996), Garcia (2002), Kılıçoğlu (2002), Kurt *vd.* (2007), Ayala *et al.* (1996) vb. gibi bilimsel çalışmalarda konu edilmiştir.

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, jeodezik nokta hız kestirimi (Yılmaz 2012), yeryuvarı dönüklük parametrelerinin kestirimi (Schuh *et al.* 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 *vd.* 2011c), koordinat dönüşümü (Barsi 2001, Lin and Wang, 2006, Yılmaz ve Güllü, 2011), uyuşumsuz ölçü testi (Güllü ve Yılmaz 2010), jeomanyetik modellere manyetik deklinasyon verisi sağlama (Yılmaz *vd.* 2010) gibi kapsamlı ölçü kümeleri ile çalışılan problemlerde, YSA uygulamaları gerçekleştirilmiştir (Yılmaz 2012).

Çalışma kapsamında Afyonkarahisar ve çevre illerini kapsayan 86 adet TUTGA noktası seçilerek oluşturulan jeodezik ağlarda, jeoit belirlemede YSA'nın kullanılabilirliği araştırılmıştır. Nokta yoğunluğunun sonuca etkisini değerlendirebilmek amacıyla bu 86 adet nokta ile 3 farklı jeodezik ağ tasarlanmıştır. YSA'nın en çok kullanılan modeli olan Geri Yayılımlı Yapay Sinir Ağı (GYRSA) ile jeoit ondülasyonları hesaplanmıştır. GYRSA'nın performansını değerlendirebilmek amacıyla bu alanda etkinliğini kanıtlamış bir model olan Kriging (KRIG) (Yaprak 2007) enterpolasyon yöntemiyle de oluşturulan ağların jeoit ondülasyonları hesaplanarak elde edilen sonuçlar karesel ortalama hata (KOH) ölçütüne göre karşılaştırılmıştır.

2. LİTERATÜR BİLGİLERİ

2.1. Jeoit Yüzeyi Modellemede Kullanılan Yöntemler

Modelleme, seçilen yüzey alanı üzerinde homojen dağılım gösteren noktalarda gerçekleştirilen ölçülerin dayanak noktası alınarak sayısal bir hesap yüzeyi geçirilmesi işlemidir (Akçın 2001). Günümüzde jeoit belirlemede en çok kullanılan modellerden başlıcaları şunlardır.

2.1.1 Polinomal Yöntemler

Bu yöntem, en yaygın kullanılan yöntemlerden biridir. Bu yöntemde amaç, arazi yüzeyini tek bir fonksiyonla ifade etmektir. (x, y, N) koordinatları ile bilinen dayanak noktalarının oluşturduğu arazi yüzeyi n . dereceden ortogonal ya da ortogonal olmayan polinomlar kullanılarak ifade edilebilir (Çakır 2012).

2.1.2 Multikuadrik Enterpolasyon Yöntemi

Bu enterpolasyon yönteminin amacı dayanak noktalarının tümünü aynı anda kullanarak araziye tek bir fonksiyonla ifade etmektir. Yöntemin uygulanmasında öncelikle, m sayıdaki noktanın dayanak noktası kullanılarak bir trend yüzeyi geçirilir. Bu yüzey için polinom, harmonik seri veya trigonometrik fonksiyonlar kullanılabilir (Yanalak 2002).

2.1.3 Ağırlıklı Ortalama İle Enterpolasyon Yöntemi

Bu yöntemde enterpolasyon noktasının yüksekliği, çevresinde bulunan dayanak noktalarının yüksekliklerinden ağırlıklı olarak hesaplanır. Her bir dayanak noktasının yüksekliğine verilecek olan ağırlık değeri o noktanın enterpolasyon noktasına olan uzaklığının bir fonksiyonudur (Yanalak 2002).

2.1.4 Sonlu Elemanlar Yöntemi

Sonlu elemanlar yöntemi, sürekli ortamların “sonlu elemanlar” adı verilen birim parçalarına ayrılarak temsil edilmesi düşüncesine dayanır. Karmaşık ve içerisinde farklı

karakteristikte ögeler barındıran bir yapının tek bir ifade ile temsil edilmesi yerine, bütünü oluşturan öğelerin, genel bütünlüğü koruyacak şekilde ifade edilmeleri sonlu elemanlar yönteminin mantıksal yaklaşımıdır (Konak *vd.* 2007).

2.1.5 Kollokasyon Yöntemi

Enterpolasyon için kullanılan fonksiyonel model, ölçüleri çoğu kez yeterli incelikte temsil etmez. Böyle durumlarda, basit bir fonksiyonel model ile birlikte ölçülerin bu modelden sapmalarını ifade eden stokastik model (=kollokasyon) öngörülmalıdır. En genel anlamıyla kollokasyon, dengeleme sayesinde bilinmeyen parametrelerin ve enterpolasyon problemlerinin bir arada çözüldüğü matematiksel bir modeldir (Ceylan *vd.* 2011).

2.1.6 Bulanık Çıkarım Sistemleri

Bulanık çıkarım sistemi, eldeki bilgileri kullanarak yeni bilgi elde etmek için, giriş ve çıkış bulanık kümeleri arasında kurulu ilişkileri bir araya toplayarak sistemin tek çıkış değeri verecek şekilde işleyişini sağlayan işlemler topluluğunun oluşturduğu mekanizmadır. Uygulamada en çok kullanılan bulanık çıkarım sistemleri, Mamdani, Tsukamoto ve Sugeno tipi sistemlerdir (Çakır 2012).

2.1.7 Radyal Tabanlı Fonksiyonlar ile Yüzey Modelleme Yöntemi

Radyal tabanlı fonksiyonlarla (RTF) enterpolasyon, 1968'de Hardy tarafından kartoğrafya alanında topoğrafik harita oluşturmak amacıyla geliştirilen Multikvadrik yöntemin genelleştirilmiş halidir (Çakır 2012).

2.2 Kriging Enterpolasyon Yöntemi

Kriging yöntemine BLUE (Best Linear Unbiased Estimator) adı verilir. Bu ismin altında yatan kestirim hatasının minimum olması şartına göre ağırlıkların belirlenmesidir. Bu durum, Kriging yöntemini diğer yöntemlerden ayıran en büyük özelliklerinden biridir (Isaak ve Srivasta 1989; İnal ve Yiğit 2003).

Bu yöntem adını bu tekniği ilk geliştiren D.G. Kriging isimli Güney Afrikalı bir maden mühendisinden almaktadır. Kriging geoistatistiksel konumsal kestirim yöntemidir. Geoistatistikte bir maden içerisindeki maden cevheri derecesinin değişimlerini kestirim etmek amacı ile bu yöntem kullanılmaktadır (Yaprak 2007). Bu yöntem, matematiksel jeodezide kollokasyon olarak bilinen en iyi lineer yansız kestirimci (BLUP [best linear unbiased predictor]) ya da en iyi lineer yansız hesaplayıcı (BLUE [Best Linear Unbiased Estimator]) olarak tanımlanır (Martensson 2002). Kriging ve kollokasyon yöntemlerinin karşılaştırılması Dermanis (1984) tarafından yapılmıştır. Kriging yöntemi bir çok alanda kullanılabilirliğini ve popüleritesini kanıtlamış geoistatistiksel bir enterpolasyon yöntemidir (Yiğit 2003). Kriging enterpolasyon yöntemi bilinen yakın noktalardan alınan verileri kullanarak diğer noktalardaki verilerin optimum değerlerini kestiren bir enterpolasyon yöntemidir (Barton *et al.* 1999). Kriging tekniği diğer kestirim tekniklerine göre daha yansız sonuçların yanı sıra minimum varyanslı ve kestirime ait standart sapmanın hesaplanmasına olanak vermektedir (Deutsch and Journel 1992; Abtew *et al.* 1993; Başkan 2004).


Kriging, daha önceden tanımlanmış bir kovaryans modelinden hesap varyansını minimize eden lineer regresyon setidir. Kriging enterpolasyon yönteminde, bir bölgede enterpole edilecek olan parametrelerin bölgesel bir değişken olduğu kabul edilir. Birbirine yakın noktalardaki veri değerlerinin daha korelasyonlu olması için bölgesel değişken konumsal olarak sürekli bir çeşitlilik gösterir (İnal ve Yiğit 2003).

Kriging yönteminin temeli bölgesel değişkenler teorisine dayanır. Yükseklikler tarafından temsil edilen olaylarda konumsal değişim yüzey boyunca istatistiksel olarak homojendir. Kriging yönteminde, en uygun ağırlıkları bulmak için, ölçme noktaları

arasındaki konumsal bağımlılığın bilinmesi gerekir. Bu konumsal bağımlılık ya bir kovaryans fonksiyonu ya da bir variogram fonksiyonu kullanmak suretiyle tanımlanabilir (Deutsch and Journal 1992; İnal ve Yiğit 2003). Kriging yöntemi ağırlıklı ortalama yöntemine benzer bir şekilde yakındaki noktalardan daha fazla etkilenmeyi sağlayan bir ağırlık modeli kullanır (İnal ve Yiğit 2003).

Kriging ile yaptığımız kestirimin doğruluğu veya geçerliliği aşağıdaki faktörlere bağlıdır. Bunlar;

- Dayanak noktalarının sayısı ve ölçü kalitesi,
- Dayanak noktalarının alan içerisindeki konumları; dayanak noktalarının topografyayı temsil edebilme yeteneği,
- Kestirimi yapılacak noktalarla, dayanak noktaları arasındaki uzaklık; kestirimi yapılacak nokta veya blokların, dayanak noktalarına yakın olması daha iyi sonuç verecektir (Mert 2005).



Şekil 2.1 Kriging kestirimi

Kestirimi yapılacak x_0 noktasına göre kriging kestirim tekniği üç şekilde uygulanabilir. Örneğin; bir bölgenin x_0 noktasındaki değer kestirimi edilmesi “noktasal kriging”, x_0

noktası merkezli bir alanının ortalama değerinin kestirimi “alansal kriging” ve x_0 noktası merkezli bir bloğun ortalama değerinin kestirimi “hacimsel kriging” olarak isimlendirilir.

Kriging yönteminin genel denklemi;

$$\hat{Z}(x_0) = \sum_{i=1}^N w_i Z(x_i) \quad (2.1)$$

şeklindedir. Burada;

N : $\hat{Z}(x_0)$ 'in kestiriminde kullanılan nokta sayısını,

$\hat{Z}(x_0)$: 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,

ifade etmektedir.

Kriging 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;

$$E[Z(x_0) - \hat{Z}(x_0)] = 0 \quad (2.2)$$

olmalıdır. Buradan,

$$E[Z(x_0) - \hat{Z}(x_0)] = E\left[Z(x_0) - \sum_{i=1}^N w_i Z(x_i)\right] = E[Z(x_0)] - \sum_{i=1}^N w_i E[Z(x_i)] = 0$$

$$E[Z(x_0)] = \sum_{i=1}^N w_i E[Z(x_i)] \Rightarrow \mu = \sum_{i=1}^N w_i \mu \Rightarrow \sum_{i=1}^N w_i = 1 \quad (2.3)$$

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;

$$E\left[Z(x_0) - \sum_{i=1}^N w_i Z(x_i)\right]^2 = -\sum_{i=1}^N \sum_{j=1}^N w_i w_j \frac{1}{2} E[Z(x_i) - Z(x_j)]^2 + 2 \sum_{j=1}^N w_j \frac{1}{2} E[Z(x_0) - Z(x_j)]^2 = 0 \quad (2.4)$$

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

$$\gamma(h) = \frac{1}{2} E[Z(x) - Z(x+h)]^2 \quad (2.5)$$

olmaktadır. Eşitlik 2.5 göz önüne alınarak,

$$E\left[Z(x_0) - \sum_{i=1}^N w_i Z(x_i)\right]^2 = -\sum_{i=1}^N \sum_{j=1}^N w_i w_j \gamma(x_i - x_j) + 2 \sum_{j=1}^N w_j \gamma(x_0 - x_j) \quad (2.6)$$

elde edilir. Eşitlik 2.6'nın 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 Kriging sistemi elde edilir. Bu sistem;

$$\sum_{i=1}^N w_i \gamma(x_i - x_j) + \lambda = \gamma(x_0 - x_j); j=1,2,\dots,N; \sum_{i=1}^N w_i = 1 \quad (2.7)$$

biçimindedir. Eşitlik 2.7'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, Kriging sistemi;

$$\begin{array}{cccccccccccc} w_1 \gamma_{11} & + & w_2 \gamma_{12} & + & \dots & + & w_N \gamma_{1N} & + & \lambda & = & \gamma_{10} \\ w_1 \gamma_{21} & + & w_2 \gamma_{22} & + & \dots & + & w_N \gamma_{2N} & + & \lambda & = & \gamma_{20} \\ \vdots & & \vdots & & \vdots & & \vdots & & \vdots & & \vdots \\ w_1 \gamma_{N1} & + & w_2 \gamma_{N2} & + & \dots & + & w_N \gamma_{NN} & + & \lambda & = & \gamma_{N0} \\ w_1 & + & w_2 & + & \dots & + & w_N & & & = & 1 \end{array} \quad (2.8)$$

şeklinde yazılabilir.

$$\gamma = \begin{bmatrix} \gamma_{11} & \gamma_{12} & \dots & \gamma_{1N} & 1 \\ \gamma_{21} & \gamma_{22} & \dots & \gamma_{2N} & 1 \\ \vdots & \vdots & \vdots & \vdots & \vdots \\ \gamma_{N1} & \gamma_{N2} & \dots & \gamma_{NN} & 1 \\ 1 & 1 & \dots & 1 & 0 \end{bmatrix}, \mathbf{w} = \begin{bmatrix} w_1 \\ w_2 \\ \vdots \\ w_N \\ \lambda \end{bmatrix}, \gamma_0 = \begin{bmatrix} \gamma_{10} \\ \gamma_{20} \\ \vdots \\ \gamma_{N0} \\ 1 \end{bmatrix} \quad (2.9)$$

olmak üzere, Kriging sistemi matris formunda;

$$\gamma \cdot \mathbf{w} = \gamma_0 \quad (2.10)$$

şeklini alır. Buradan \mathbf{w} ; bilinmeyenler (ağırlıklar) matrisi;

$$\mathbf{w} = \gamma^{-1} \cdot \gamma_0 \quad (2.11)$$

denklem sistemine göre çözümlenir.

Ağırlıklar belirlendikten sonra, Eşitlik 2.1 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 kriging algoritmasında her bir yeni nokta için ağırlık hesabının tekrarlı olarak bulunması anlamına gelmektedir (İnal ve Yiğit 2003).

KRIG yöntemi ile yapılan kestirimin varyansı (Kriging varyansı);

$$\sigma_K^2 = 2 \sum_{i=1}^N w_i \gamma(x_0 - x_i) - \sum_{i=1}^N \sum_{j=1}^N w_i w_j \gamma(x_i - x_j) = \sum_{i=1}^N w_i \gamma(x_0 - x_i) + \lambda \quad (2.12)$$

şeklinde hesaplanır.

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

Kriging 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).

Genel olarak; ortalama (m) kestirim edicisi bilinmeden yapılan kriging “Ordinary Kriging (OK)” ve kriging kestirim edicisi ortalama (m)’nın bilinmesiyle yapılan kriging “Simple Kriging (SK)” olarak tanımlanır (David 1988).

Bugün Kriging yöntemleri yaygın olarak aşağıda sıralanan adlarla çeşitli alanlarda kullanılmaktadır. Kullanılan bu yöntemler;

- Simple Kriging
- Ordinary (Punctual) Kriging
- Universal Kriging
- Block Kriging
- Indicator Kriging
- Disjunctive Kriging
- Cokringing

olarak sıralanabilir (Yaprak 2007).

Kriging yönteminin jeodezik uygulamalarda kullanılabilirliği İnal ve Yiğit (2003), Yaprak (2007), Yaprak ve Arslan (2008), Başkan (2004), Trangmar *et al.* (1985), Yiğit (2003), Isaaks ve Srivastava (1989) vb. gibi çalışmalarda araştırılmıştır. Bu araştırmaların sonucunda Kriging yönteminin uygulamalarda karşılaştırılan birçok yöneme göre daha iyi sonuçlar verdiği görülmüştür. Jeoit yüzeyi modellemede Yaprak (2007) tarafından kullanılmış ve Ordinary Kriging yönteminin deterministik enterpolasyonlar içerisinde en iyi sonucu veren Multikuadrik yöntemden daha iyi sonuçlar verdiği belirtilmiştir.

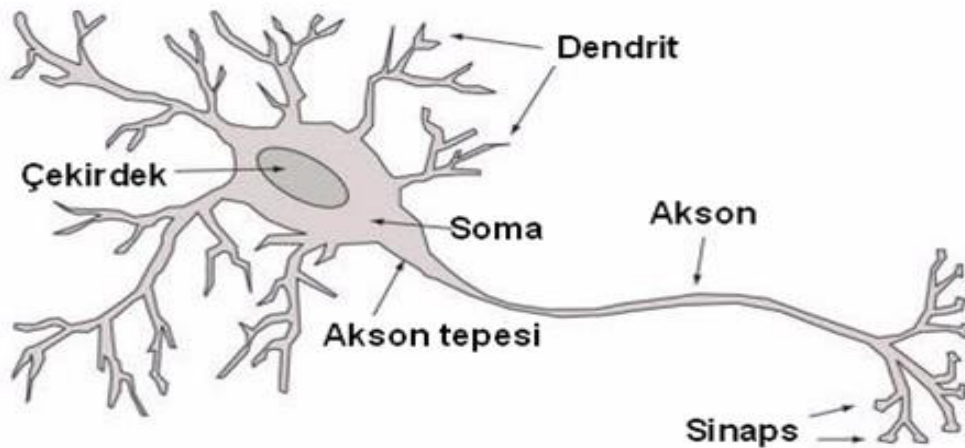
2.3 Yapay Sinir Ağları

2.3.1 Biyolojik Sinir Sistemi

Kullanıcının geleneksel yeteneklerini gerektirmeyen ve kendi kendine öğrenme düzenekleri olan YSA, beynin fizyolojik yapısından esinlenerek geliştirilmesine karşın, tüm özellikleri beyinle aynı değildir. Bazı özelliklerinin ise beyinde biyolojik karşılığı yoktur. YSA'nın çalışma mantığını anlamak için insan beyninin yapısını ve çalışma şeklini yani biyolojik sinir sisteminin yapısını incelemekte yarar vardır.

2.3.2 Biyolojik Sinir Hücresinin Yapısı

Biyolojik sinir sisteminin temel işlem elemanı olan biyolojik sinir hücresinin yapısı Şekil 2.2'den de görüleceği üzere çekirdek, dendritler, soma (hücre gövdesi), akson ve sinapstan oluşur. Bir hücrede birden fazla sayıda bulunabilen dendritler, diğer hücrelerin sinapsları aracılığıyla gelen bilgileri alan, sinir hücresinin ucunda bulunan ağaç kökü görünümüne sahip kısa uzantılardır. Soma (hücre gövdesi), dendritlerden gelen bilgileri toplayarak zaman içinde işler ve işlenen bilgi potansiyel bir eşik değerine ulaşırsa akson aracılığıyla diğer hücrelere iletilir. Sinapslar, akson ve diğer sinir hücrelerinin dendritleri arasındaki bağlantıyı sağlar (Çakır 2012).



Şekil 2.2 Biyolojik Sinir Hücresi

Beynimizde yaklaşık 10 milyar sinir hücresi ve 60 trilyondan fazla sayıda sinaptik bağlantılar vardır. Bu özelliğinden dolayı insan beyni, yapay sinir ağları ile karşılaştırıldığında son derece karmaşık bir yapıya sahiptir (Haykin 1999). Diğer taraftan biyolojik sinir hücreleri bir işleme milisaniye mertebesinde cevap verirken, günümüz bilgisayar işlemcileri nanosaniye mertebesinde cevap vermektedir. Bu ifadeye göre bilgisayarların insan beynine göre hız bakımından daha avantajlı olduğu söylenebilir. Ancak matematiksel hesaplama gerektiren uygulamalarda YSA'lar insandan her zaman üstün ve hata olasılığı çok düşük olmasına rağmen, eksik bilgi ile görme, hata düzeltme, şekil tanıma gibi işlemlerde insan beyni çok daha hızlı ve etkin sonuçlar üretmektedir. Bunun sebebi, bilgisayar işlemcilerinin seri olarak çalışmasına karşın, insan beyninin doğrusal olmayan ve paralel dağılmış bir bilgi işleme sistemine sahip olduğu için çok karmaşık olayları bile yüksek performansta işleyebilecek yeteneğe sahip olmasındadır. Yapay sinir ağları ile bu yeteneğin bilgisayarlara kazandırılması amaçlanmaktadır (Öztemel 2003; Şen 2004).

2.3.3 Yapay Sinir Ağı Tanımı

İnsanoğlu, doğadaki ve canlılardaki benzer işleyişe sahip sistemleri gözlemleyerek, sebep-sonuç ilişkilerini yorumlayarak, günlük hayatta karşılaştığı problemlere çözüm üretmeye çalışmıştır. Örneğin, uçağın kanatlarının yapımında akbaba kanatlarının yapısı model alınırken, yarasaların çok yüksek titreşimli ses dalgaları yayıp çevredeki engellere çarpıp yansması sonucu, yönünü ve hareket hızını belirlemesinden yola çıkarak da radarların çalışma ilkesi belirlenmiştir (Çakır 2012).

Yapay sinir ağlarının kullanım çeşitliliğinin fazla olması nedeniyle araştırmacılar, genel bir tanımdan çok YSA türlerinin kendi içlerinde tanımlanması gerektiğini savunurlar. Bununla birlikte bazı genel tanımlamalarda mevcuttur. Bunlardan bazıları şu şekildedir.

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).


YSA çalışmalarının tarihsel gelişimine bakıldığında ilk çalışmalar, nörofizyolog Warren McCulloch ve matematikçi Walter Pitts'in (1943) sadece girdi ve çıktıları olan basit bir sinir ağı modellemesiyle başlamaktadır. 1949 yılında Hebb, isminin verildiği Hebbian Kuralını ortaya koymuş ve Frank Rosenblatt'ın (1958) öğrenme yeteneğini kazandırdığı tekli doğrusal algılayıcı (Perceptron) modelini geliştirmesinden sonra, YSA ile ilgili çalışmalar hız kazanmıştır (Çakır 2012).

Widrow ve Hoff (1960), ADALINE (ADaptive LInear NEuron) ve MADALINE modelini ortaya atmışlardır. Bununla birlikte, ağı eğitimi boyunca toplam hatayı en aza indirmeyi hedefleyen Widrow-Hoff öğrenme kuralını geliştirdiler. MADALINE, telefon hatlarında oluşan yankıları yok etmede kullanılmış, gerçek dünya sorunlarına uygulanmış ilk sinir ağıdır ve hala kullanılmaktadır. 1969 yılında Minsky ve Pappert yazdıkları 'Algılayıcılar' (perceptrons) adlı kitapta YSA'nın doğrusal olmayan problemlere çözüm üretemediğini ve birçok mantıksal operasyonu (XOR problemi) çözemediğini iddia etmişlerdir. Bu durum 1980'lere kadar YSA çalışmalarında durgunluk yaratmıştır. Hopfield (1982) tarafından doğrusal olmayan ağların geliştirilmesi, Kohonen'in (1972) eğitimcisiz öğrenen algoritmaları geliştirmesi ve Rumelhart ve arkadaşları (1986) tarafından çok katmanlı ağlar için geriye yayılmalı

öğrenme algoritmalarının geliřtirmesiyle de YSA üzerinde yapılan çalıřmalar dünyada büyük bir hız kazanmıřtır (Haykin 1999; Elmas 2003; řen 2004).

2.3.4 Yapay Nöron

YSA'nın çalıřmasına esas teřkil eden temel eleman, yapay nöron (nöron) adı verilen bilgi iřleme birimidir. YSA, nöronlar arasında baęlantılar kurularak ve katmanlar halinde gruplandırılarak oluřturulur. Geliřtirilen nöron modellerinde bazı farklılıklar olmakla birlikte genel özellikleri ile bir nöron; řekil 2.3'de görüldüğü gibi, girdiler (x_i), aęırlıklar (w_i), eřik deęeri (b), toplama fonksiyonu (T), aktivasyon fonksiyonu (f) ve çıktı (y) olmak üzere altı temel bileřenden meydana gelir (Yılmaz 2012).



řekil 2.3 Yapay nöronun bileřenleri (Kaftan 2010)

Girdiler: Nörona dıř dünyadan veya diđer nöronlardan gelen, YSA'nın öęrenmesi istenen bilgilerdir.

Aęırlıklar: Aęırlıklar bir nörona gelen bilginin önemini ve nöron üzerindeki etkisini gösteren baęlantılardır. Girdiler, aęırlık deęerleri ile çarpılarak diđer nörona gönderilir. Aęırlık deęerinin sıfır olması herhangi bir etki olmadığını, artı veya eksi olması ise etkinin pozitif veya negatif olduęunu 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).

$$T = \sum_{i=1}^n x_i w_i + b \quad (2.13)$$

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 fonksiyonunun sürekli olması türevinin alınması, türevinin alınması da YSA'nın eğitimi aşamasındaki algoritmaları için gereklidir. Aktivasyon fonksiyonunun 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 kullanılabilen 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 2.1'de, grafikleri ise Şekil 2.4'de verilmektedir.

Çizelge 2.1 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 2.4 Aktivasyon fonksiyonlarının grafikleri (Yılmaz 2012)

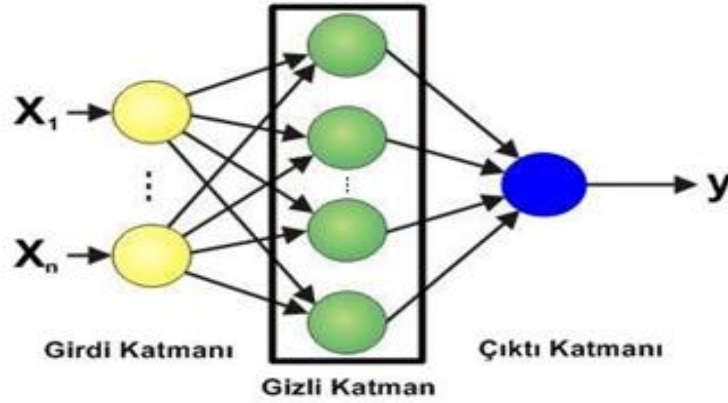
Çıktı: Aktivasyon fonksiyonu tarafından hesaplanan $y = f(T)$ değeri, nöronun çıktı değeridir. Bazı durumlarda, nöron tarafından bir çıkış fonksiyonu yardımıyla çıktıya ölçeklendirme ve sınırlandırma işlemi uygulanması gerekebilir. YSA'nın yapısına göre, üretilen çıktı değeri başka bir nörona girdi olarak 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 kümelenmesini ve aralarındaki bağlantıların oluşturulmasını içermektedir (Yılmaz 2012).

2.3.5 Yapay Sinir Ağlarının Yapısı

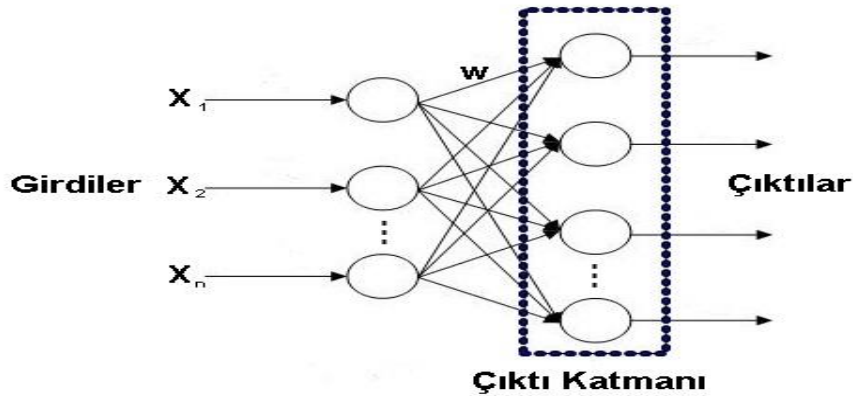
YSA'larda, nöronların kümelenmesi işlemi katmanlar halinde yapılmaktadır ve daha

sonra bu katmanlar birbirleri ile ilişkilendirilmektedir. Temel olarak bir YSA'nın genel yapısı, Şekil 2.5'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 kümelendirilmiştir yani, sadece YSA içinde bağlantıları bulunmaktadır (Yılmaz 2012).



Şekil 2.5 Çok katmanlı yapay sinir ağlarının genel yapısı (Yılmaz 2012)

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 2.6)(Yılmaz 2012).



Şekil 2.6 Tek katmanlı yapay sinir ağları (Yılmaz 2012)

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 2.6) ihtiyaç duymaktadır (Yılmaz 2012).

Girdi katmanı: Gelen bilgilerin işlenmeden YSA'ya iletiildiği 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 (Yılmaz 2012).

2.3.6 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).

2.3.6.1 Bağlantı Yapılarına Göre Yapay Sinir Ağları

a. 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 2.7'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).

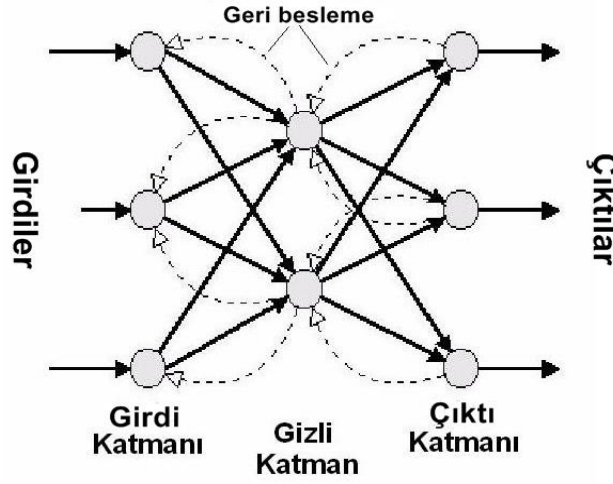


Şekil 2.7 İleri beslemeli yapay sinir ağları (Yılmaz 2012)

b. 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 ağıları verilebilir (Nabiyev 2010). Geri beslemeli YSA'nın genel yapısı Şekil 2.8'de verilmektedir.



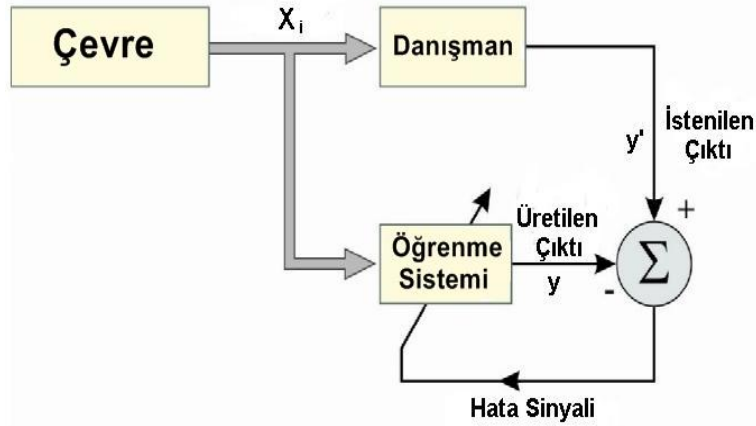
Şekil 2.8 Geri beslemeli yapay sinir ağı (Yılmaz 2012)

2.3.6.2 Öğrenme Algoritmalarına Göre Yapay Sinir Ağları

YSA'lar, insan beyni gibi öğrenme yeteneğine sahip olmaları nedeniyle, klasik programlama gibi belirli bir algoritma çerçevesinde programlanmazlar. YSA'da bilgi, ağdaki 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 (Yılmaz 2012).

a. 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 (Yılmaz 2012).




Şekil 2.9 Danışmanlı öğrenme yapısı (Yılmaz 2012)

Şekil 2.9'da 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.

b. 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).

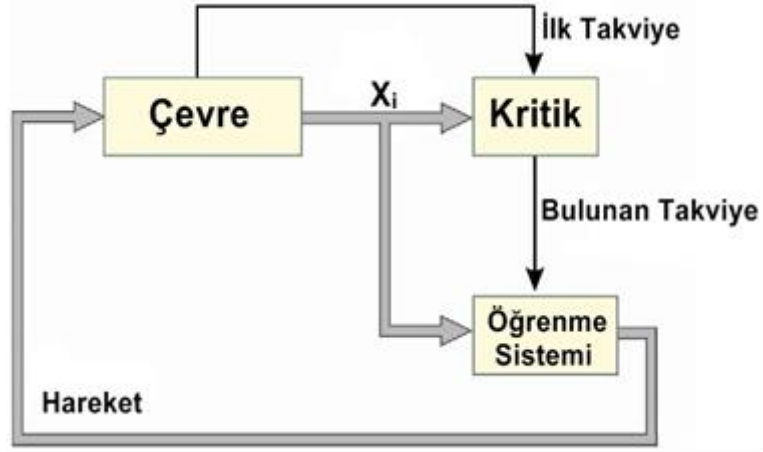


Şekil 2.10 Danışmansız öğrenme yapısı (Yılmaz 2012)

Şekil 2.10'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.

c. 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 2.11'de takviyeli öğrenme yapısı gösterilmektedir. Optimizasyon problemlerini çözmek için geliştirilen Boltzmann kuralı (Hinton and Sejnowski 1986) takviyeli öğrenmeye örnek olarak verilebilir (Yılmaz 2012).



Şekil 2.11 Takviyeli öğrenme yapısı (Yılmaz 2012)

2.3.7 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.

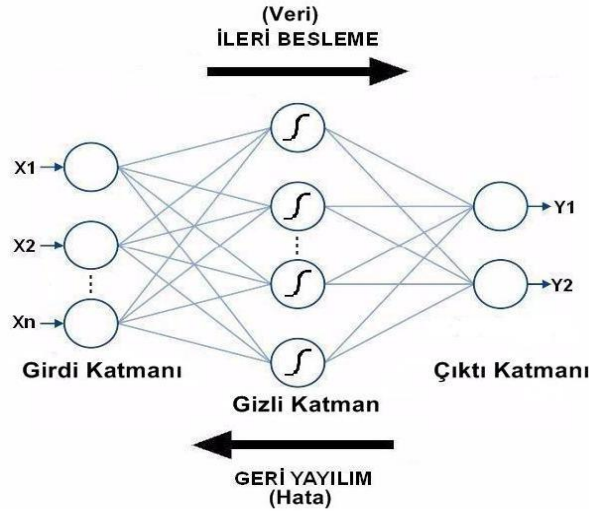
Genelleştirilmiş delta kuralı: Geri yayılım algoritması olarak da bilinen bu kural, en küçük kareler ortalamasına dayanan delta kuralının genelleştirilmiş halidir. Bağlantı ağırlıklarının değiştirilmesi için YSA'da kullanılan aktivasyon fonksiyonunun birinci derece türevi kullanılmaktadır.

2.3.8 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 2.1'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, GYRSA'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 2.12’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 2.12 Geri yayımlı yapay sinir ağı (Yılmaz 2012)

2.3.8.1 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(Yılmaz 2012).

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:

$$\varepsilon_j(k) = y'_j(k) - y_j(k) \quad (2.14)$$

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:

$$e(k) = \frac{1}{2} \sum_{j=1}^K \varepsilon_j^2(k) \quad (2.15)$$

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

$$e_{ort} = \frac{1}{N} \sum_{n=1}^N e(k) \quad (2.16)$$

$e(k)$ 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:

$$T_j(k) = \sum_{i=0}^n w_{ij}(k) \cdot x_i(k) \quad (2.17)$$

Eşitlik 2.17'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:

$$y_j(k) = f_j(T_j(k)) = \frac{1}{(1 + e^{-T_j(k)})} \quad (2.18)$$

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:

$$\frac{\partial e(k)}{\partial w_{ij}(k)} = \frac{\partial e(k)}{\partial \varepsilon_j(k)} \cdot \frac{\partial \varepsilon_j(k)}{\partial y_j(k)} \cdot \frac{\partial y_j(k)}{\partial T_j(k)} \cdot \frac{\partial T_j(k)}{\partial w_{ij}(k)} \quad (2.19)$$

$\frac{\partial e(k)}{\partial w_{ij}(k)}$ kısmi türevi, w_{ij} ağırlığı için, ağırlık uzayında aramanın yönünü belirleyen bir duyarlılık faktörüdür. Eşitlik 2.15'in her iki tarafının, $\varepsilon_j(k)$ 'ye göre türevi alınır;

$$\frac{\partial e(k)}{\partial \varepsilon_j(k)} = \varepsilon_j(k) \quad (2.20)$$

elde edilir. Eşitlik 2.14'de her iki tarafın, $y_j(k)$ 'ye göre türevi alınır;

$$\frac{\partial \varepsilon_j(k)}{\partial y_j(k)} = -1 \quad (2.21)$$

elde edilir. Ayrıca Eşitlik 2.18'de her iki tarafın, $T_j(k)$ 'ye göre türevi alınır;

$$\frac{\partial y_j(k)}{\partial T_j(k)} = f'_j(T_j(k)) \quad (2.22)$$

elde edilir. Son olarak Eşitlik 2.17'de her iki tarafın, $w_{ij}(k)$ 'ye göre türevi alınır;

$$\frac{\partial T_j(k)}{\partial w_{ij}(k)} = x_i(k) \quad (2.23)$$

elde edilir. Eşitlik 2.20, 2.21, 2.22 ve 2.23'deki türevler, Eşitlik 2.19'da ifade edilen zincir kuralına uygulanırsa, söz konusu eşitlik;

$$\frac{\partial e(k)}{\partial w_{ij}(k)} = -\varepsilon_j(k) \cdot f'_j(T_j(k)) \cdot x_i(k) \quad (2.24)$$

biçiminde yazılabilir.

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

$$w_{ij}(k+1) = w_{ij}(k) + \Delta w_{ij}(k) \quad (2.25)$$

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

$$\Delta w_{ij}(k) = w_{ij}(k+1) - w_{ij}(k) \quad (2.26)$$

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

$$\Delta w_{ij}(k) = -\eta \frac{\partial e(k)}{\partial w_{ij}(k)} \quad (2.27)$$

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 2.27'de,

$\frac{\partial e(k)}{\partial w_{ij}(k)}$ değeri yerine yazılırsa;

$$\Delta w_{ij}(k) = \eta \delta_j(k) x_i(k) \quad (2.28)$$

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

$$\delta_j(k) = -\frac{\partial e(k)}{\partial T_j(k)} = -\frac{\partial e(k)}{\partial \varepsilon_j(k)} \cdot \frac{\partial \varepsilon_j(k)}{\partial y_j(k)} \cdot \frac{\partial y_j(k)}{\partial T_j(k)} = \varepsilon_j(k) \cdot f'_j(T_j(k)) \quad (2.29)$$

şeklinde yazılır.

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

$$w_{ij}(k+1) = w_{ij}(k) + \eta \delta_j(k) x_i(k) \quad (2.30)$$

olarak elde edilir. Eşitlik 2.30; geri yayılım algoritmasının en genel ifadesidir. Basit bir metot olan öğrenme oranının artırılmasında, kararsızlık tehlikesinden kaçınmak için,

α , momentum katsayısını içeren, Eşitlik 2.28'in düzenlenmiş hali aşağıdaki gibidir:

$$\Delta w_{ij}(k) = \alpha \Delta w_{ij}(k-1) + \eta \delta_j(k) x_i(k) \quad (2.31)$$

Burada momentum katsayısı, genellikle pozitif bir sayı olarak kullanılır. Eşitlik 2.31'de, Eşitlik 2.28'dan farklı olarak, ağırlıkların önceki değeri de yeni ağırlıkta etkili olmaktadır. Eşitlik 2.31; 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 sağlamak 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 ağırlıklar 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 (Yılmaz 2012).

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 ulaşamayabilir (Özaydın 2009). Fazla gizli nöron sayısı ile test setinin hatası belirli bir değere kadar indirgenmekte fakat daha sonra bu hata oranı artmaya başlamaktadır (Şekil 2.13)(Yılmaz 2012).



Şekil 2.13 Gizli katmandaki nöron sayısına göre eğitim ve test setlerinin hata eğrileri (Yılmaz 2012)

Gizli katmandaki nöron sayısının artırılması durumunda GYSSA'nın yapısı karmaşıklaşmakta fakat bununla birlikte hata oranı azalmaktadır. GYSSA'nın gizli katmanındaki nöronların sayısının belirlenmesi için özel bir kural yoktur fakat başlangıç noktası olarak kullanılabilir 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 GYSSA'da da, doğru çözüme ulaşmak için doğru verilere ihtiyaç vardır. Eğer girdi veri kümesi, problemi yeterince iyi karakterize edemiyorsa, GYSSA problemi çözmede yetersiz kalacaktır. GYSSA, 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, GYSSA'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 öznelik 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: GYSSA'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 kullanılabilir 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 (Yılmaz 2012).


Öğrenme sürecinin sonlandırılması: Öğrenme sürecini sonlandırmanın en kolay yolu, tekrarlamaya sayısının sınırlandırılmasıdır. Fakat bu yöntemle elde edilen katsayıların en iyi olduklarından asla emin olunamaz. Öğrenme sürecini sonlandırmak için kullanılacak 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-çıkış 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 (Yılmaz 2012).

Geril 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. 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 2.14) (Efe ve Kaynak 2004).



Şekil 2.14 Öğrenme sürecini sonlandırma aralığı (Yılmaz 2012)

GYRSA eğitimi için kullanılan standart geri yayılım algoritmasında izlenen adımlar Şekil 2.15’de verilmektedir.



Şekil 2.15 Geri yayılım algoritması için akış diyagramı (Yılmaz 2012)

2.3.9 Yapay Sinir Ağlarının Üstünlükleri ve Sınırlamaları

İnsanlardaki merkezi sinir sisteminin matematiksel modellenmesi 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 (Yılmaz 2012).

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 (Yılmaz 2012).

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 (Yılmaz 2012).

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 (Yılmaz 2012).

Genelleme: YSA, öğrenme yeteneği sayesinde bilinen örnekleri kullanarak daha önce karşılaşılmamış durumlarda genelleme yapabilmekte, bozuk veya kayıp veriler için çözüm üretebilmektedir (Yılmaz 2012).

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 (Yılmaz 2012).

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 (Yılmaz 2012).

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 (Yılmaz 2012).

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 (Sağiroğlu 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 (Yılmaz 2012).

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 (Yılmaz 2012).

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 çözülememiş 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).

2.3.10 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/tanıma
- 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 (Yılmaz 2012)

2.3.10.1 Yapay Sinir Ağlarının Harita Mühendisliğindeki Kullanım Alanları

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;


- Jeoit tespiti (Güllü *vd.* 2011b)
- Deformasyon analizi (Neuner 2010)
- Yer dönüklük parametrelerinin kestirimi (Liao *et al.* 2012)
- Uyuşumsuz ölçülerin tespiti (Güllü ve 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 ve 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.

3. MATERYAL VE METOD

3.1. Çalışma Alanı ve Veri Seti

Uygulamada HGK'nın Türkiye Hibrit Jeoit Modeli-2009'dan temin edilen veriler kullanılmıştır. Bu model, Yer Jeopotansiyel modeli 2008, denizlerde uydu altimetre ölçülerinden hesaplanan 1'x 1' aralıklı DNSC08 gravite anomalileri, 3"x 3" aralıklı sayısal arazi modeli ve 2714 adet GPS/Nivelman noktası kullanılarak Hızlı Fourier Dönüşümü yöntemiyle hesaplanmıştır. Jeoit yükseklikleri uzun, orta, kısa dalga boylu parçaların bir toplamı şeklinde modellenmiş ve her parça ayrıca hesaplanarak sonuç jeoit modeli belirlenmiştir. Bu modelin iç duyarlılığı ± 1 cm., dış doğruluğu ise ± 9 cm. seviyesindedir(URL-2).




Şekil 3.1 Türkiye Hibrit Jeoid Modeli-2009 (URL-2)

Uygulamanın gerçekleştirildiği çalışma alanı olarak; Afyonkarahisar ili ve çevresindeki illeri kapsayan $37^{\circ}.43 < \varphi < 40^{\circ}.40$; $28^{\circ}.50 < \lambda < 32^{\circ}.50$ coğrafi sınırlar arasındaki yaklaşık 360 km x 340 km ($\sim 122\ 400$ km²) yüzölçümlü bölge seçilmiştir (Şekil 5.2).

Çalışma alanında bulunan ve konumsal dağılımları Şekil 5.2'de gösterilen toplam 86

adet TUTGA noktasının koordinatları ile HGK tarafından belirlenmiş jeoit yükseklikleri, uygulama veri seti olarak düzenlenmiştir.



Şekil 3.2 Çalışma alanı ve jeodezik noktaların coğrafi dağılımı

3.2. Uygulamanın Amacı

Bu çalışmada yapılan uygulamanın amacı; çalışma alanı olarak seçilen Afyonkarahisar ve çevresindeki illerde oluşturulan jeodezik ağlarda, YSA ve Kriging yöntemleri ile modellenen lokal jeoit yüzeylerini karşılaştırarak, YSA yönteminin lokal jeoit yüzeyi modellemesi probleminde kullanılabilirliğinin araştırılmasıdır.

3.3. Uygulama Metodolojisi


Bu çalışma kapsamında; toplam 86 adet TUTGA noktasından oluşturulan veri seti uygulama için, referans ve test olarak iki ayrı alt sete ayrılarak kullanılmıştır. Referans

veri seti; YSA eğitiminde ve Kriging yönteminde jeoit yüzeyinin oluşturulmasında kullanılmıştır. Test veri seti ise eğitilmiş YSA'nın performansının değerlendirilmesinde ve Kriging yönteminin kestirim doğruluğunun belirlenmesinde kullanılmıştır.


YSA'nın eğitiminde ve kriging yöntemi için jeoit yüzeyi modelinin oluşturulmasında kullanılan referans veri setindeki nokta yoğunluğunun jeodezik noktaların jeoit yüksekliği hesaplamasına olan etkisini değerlendirebilmek amacıyla mevcut veri setinden üç farklı jeodezik ağ modeli oluşturularak (Çizelge 5.1), tüm jeoit yüksekliği hesaplamaları bu üç model üzerinde gerçekleştirilmiştir.

Çizelge 3.1 Oluşturulan jeodezik ağ modelleri


Model	Nokta Sayısı		Nokta Yoğunluğu (km ² /nokta)	
	Referans	Test	Referans	Test
1	36	50	~ 3 400	~ 2 500
2	46	40	~ 2 700	~ 3 000
3	56	30	~ 2 200	~ 4 100



Şekil 3.3 1 no'lu jeodezik ağ modeli (▲ → Referans; ● → Test)




Şekil 3.4 2 no'lu jeodezik ağ modeli (▲ → Referans; ● → Test)




Şekil 3.5 3 no'lu jeodezik ağ modeli (▲ → Referans; ● → Test)

Jeodezik ağlarda jeoit yüksekliklerinin GYYSA ile kestiriminde ilk olarak, girdi ve çıktı veri setleri oluşturulmuştur. Referans ve test noktalarının koordinatları, girdi verisi olarak ve noktanın jeoit yükseliği, çıktı verisi olarak kullanılmıştır. Yeterli sayıda nöron kullanıldığında tek gizli katmana sahip GYYSA 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 GYYSA modülünde, katmanlardaki nöron sayılarına göre [2:11:1] yapısına sahip YSA tasarlanmıştır. Referans noktasının en fazla olduğu Model - 3 üzerinde YSA'nın eğitim işlemi gerçekleştirilerek en küçük HKO (Hata Kareleri Ortalaması)'yu üreten, öğrenme oranı, momentum katsayısı ve başlangıç ağırlık değerleri şeklindeki GYYSA parametreleri; diğer 2 model üzerinde gerçekleştirilen eğitim işleminde başlangıç değerleri olarak kullanılmıştır.


Kriging yöntemi ile jeoit yüksekliklerinin kestiriminde, jeodezik ağ modellerindeki referans noktaları kullanılarak her jeoit yüksekliği için referans jeoit yüzey modeli oluşturulmuş 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 jeoit yüksekliği kestirimi yapılarak oluşturulan jeoit yüzey modelinin doğruluğu kontrol edilmiştir. Arcgis Geostatistical Analyst modülü kullanılarak 2. derece trend yüzeyli Ordinary Kriging yöntemi ile test noktalarının jeoit yükseklikleri hesaplanmış ve jeoit yüzey modeli oluşturulmuştur.




Şekil 3.6 1. Veriseti test noktaları jeoit yüksekliği yüzey modeli (— HGK değeri, — Kriging hesap değeri)




Şekil 3.7 1. Veriseti test noktaları jeoit yüksekliği yüzey modeli (— HGK değeri, — YSA hesap değeri)




Şekil 3.8 2. veriseti test noktaları jeoit yüksekliği yüzey modeli (— HGK değeri, — Kriging hesap değeri)



Şekil 3.9 2. veriseti test noktaları jeoit yüksekliği yüzey modeli (— HGK değeri, — YSA hesap değeri)



Şekil 3.10 3. veriseti test noktaları jeoit yüksekliği yüzey modeli (— HGK değeri, — Kriging hesap değeri)



Şekil 3.11 3. veriseti test noktaları jeoit yüksekliği yüzey modeli (— HGK değeri, — YSA hesap değeri)

Jeodezik ađ modellerindeki referans veri setlerine dayalı olarak eđitilmiş GYYSA kullanılarak ve referans hız alanlarına göre oluşturulmuş jeoit yüksekliđi yüzeylerine göre Kriging yöntemi kullanılarak söz konusu modellerdeki test noktalarının jeoit yükseklikleri hesaplanmıştır. GYYSA'nın, jeoit yüksekliđi hesaplamasındaki performansının belirlenebilmesi ve Kriging yöntemi ile hesaplanan nokta yüksekliklerinin dođruluđunun tespit edilebilmesi amacıyla, test noktalarına ait HGK tarafından TUTGA kapsamında belirlenmiş temel jeoit yükseklik deđerleri ile GYYSA ve KRIG ile hesaplanmış jeoit yüksekliđi deđerleri arasındaki yükseklik farkları (ΔN) ařađıdaki řekilde hesaplanmıştır.

$$\Delta N = N(TUTGA) - N(GYYSA, Kriging) \quad (3.1)$$

Elde edilen Δh 'ların istatistiksel analizi için, minimum, maksimum, ortalama ve KOH deđerleri hesaplanmış ve ΔN 'lar; hesaplanan ve bilinen model deđerleri arasındaki küçük farklara bile duyarlı olan (Yılmaz ve Güllü 2011), enterpolasyon yöntemlerinin hata hesabında global olarak kullanılan (Erdođan 2010) ve YSA uygulamalarında sonuçların deđerlendirilmesinde etkin olan (Wolfram 2005, Schroeder *et al.* 2009) KOH ölçütüne göre incelenmiştir.

$$KOH = \sqrt{\frac{1}{n} \sum_{i=1}^n (\Delta N)^2} \quad (3.2)$$

Buradaki n ; hesaplanan jeoit yüksekliđinin yani modeldeki test noktasının sayısını ifade etmektedir.


4. BULGULAR VE SONUÇLAR

Jeodezik ağılarda jeoit yüksekliğinin YSA ve Kriging yöntemi ile hesaplanması uygulamasında; YSA modellerinin eğitiminde ve Kriging için jeoit yüzeylerinin oluşturulmasında kullanılmayan test veri setinin performansı belirleyici olmaktadır. Bu nedenle, elde edilen sonuçların değerlendirilebilmesi amacıyla jeodezik ağ modellerindeki test noktalarının jeoit yüksekliği değerleri ile YSA ve Kriging ile hesaplanmış yükseklik değerleri arasındaki farklara göre, yükseklik fark haritaları düzenlenmiştir.


Model - 1'e ilişkin Şekil 3.6, 3.7 ve 4.1, 4.2 birlikte değerlendirildiğinde; test noktalarına ait yükseklik değerlerinin YSA tarafından Kriging yöntemine göre daha doğru modellendiği değerlendirilmektedir.

Model - 2 ile ilgili Şekil 3.8, 3.9 ve 4.3, 4.4 incelendiğinde; YSA ve Kriging yöntemlerinin arasındaki fark yakın olmasına rağmen YSA'nın daha iyi modellendiği değerlendirilmektedir.


Model - 3'e ait Şekil 3.10, 3.11 ve 4.5, 4.6'dan; Kriging yönteminin daha iyi modellenmiş olmasına rağmen belirgin bir fark olmadığı değerlendirilmektedir.




Şekil 4.1 1. Model HGK yükseklik değerleri ile Kriging yöntemi arasındaki yükseklik fark haritası




Şekil 4.2 1. Model HGK yükseklik değerleri ile YSA yöntemi arasındaki yükseklik fark haritası




Şekil 4.3 2. Model HGK yükseklik değerleri ile Kriging yöntemi arasındaki yükseklik fark haritası



Şekil 4.4 2. Model HGK yükseklik değerleri ile YSA yöntemi arasındaki yükseklik fark haritası




Şekil 4.5 3. Model HGK yükseklik değerleri ile Kriging yöntemi arasındaki yükseklik fark haritası



Şekil 4.6 3. Model HGK yükseklik değerleri ile YSA yöntemi arasındaki yükseklik fark haritası

YSA ve Kriging yöntemlerinin nokta yükseklik kestirimindeki performanslarının birlikte değerlendirilebilmesi amacıyla, jeodezik ağ modelleri üzerinde hesaplanan jeoit yüksekliği farklarının KOH ölçütüne göre karşılaştırılması Şekil 4.7’de verilmiştir.



Şekil 4.7 Hesaplanan yükseklik farklarının KOH değerleri

YSA ve Kriging yöntemleri ile elde edilen, test noktalarına ait yükseklik farklarının kendi aralarında istatistiksel olarak karşılaştırılmasında kullanılmak üzere söz konusu yükseklik farklarının minimum, maksimum ve ortalama değerleri hesaplanarak, KOH değerleri ile birlikte Çizelge 4.1’de verilmiştir.

Çizelge 4.1 Hesaplanan yükseklik farklarının mutlak istatistiksel değerleri (m.)

MODEL 1	YSA	Kriging
Minimum	0.005	0.002
Maksimum	0.65	0.71
Ortalama	0.14	0.15
KOH	0.18	0.20
MODEL 2	YSA	Kriging
Minimum	0.007	0.01
Maksimum	0.49	0.43
Ortalama	0.13	0.15
KOH	0.17	0.18
MODEL 3	YSA	Kriging
Minimum	0.001	0.01
Maksimum	0.41	0.45
Ortalama	0.12	0.12
KOH	0.153	0.152

Bu çalışmanın amacı; mekansal kestirim problemi olarak ele alınan jeoit yüksekliği hesabında YSA'nın kullanılabilirliğinin araştırılması olup, çalışma kapsamında elde edilen verilerin tamamı (Şekil 3.6-4.7 ve Çizelge 3.1-4.1) birlikte değerlendirildiğinde, jeoit yüksekliklerinin, jeodezik ağda bulunan ve yükseklik 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 yöntemi (GYSA) KRIG yöntemiyle karşılaştırıldığında, genel olarak lokal jeoit yüzeyi modellemede kullanılabilir olduğu görülmüştür.
- Referans nokta sayısının test nokta sayısından az olduğu Model 1'de YSA yöntemi Kriging yönteminden çok daha iyi sonuçlar elde etmiş olup, yüksekliği

bilinen nokta yoğunluğunun 3400 km² /nokta'dan düşük olduğu ve çok sayıda noktanın jeoit yüksekliği hesaplanmasına ihtiyaç duyulduğu jeodezik ağlarda, YSA'nın etkin bir şekilde kullanılabilceği görülmektedir.

- Referans nokta sayısının test nokta sayısına hemen hemen eşit olduğu Model 2'de YSA yöntemi ile Kriging yöntemi arasındaki fark Model 1'den daha düşük olmasına rağmen YSA'nın bu modelde de daha iyi sonuçlar verdiği görülmektedir.
- Referans nokta sayısının test nokta sayısından fazla olduğu Model 3'de Kriging yöntemi, YSA yönteminden daha iyi sonuç verdiği görülmektedir. Ancak fark mm. boyutunda olup bu tür jeodezik ağlarda da YSA'nın kullanılabilir bir seçenek olduğu düşünülmektedir.
- Jeoit yüksekliği hesaplanması problemi için genel kapsamda kullanılabilir olarak değerlendirilen YSA'nın Kriging'e göre temel avantajı, esnek yapısı nedeniyle belirli bir matematiksel model izleme zorunluluğunun bulunmaması ve normal dağılımlı olmayan verilere de uygulanabilmesidir.

5. KAYNAKLAR

- Abtew, W., Obeysekera, J. and Shih, G., (1993). Spatial analysis for monthly rainfall in South Florida, *Water Resources Bulletin*, **29**: 179-188
- Alavala, C.R. (2007). Fuzzy Logic and Neural Networks: Basic Concepts and Applications. *New Age International Publishers*, New Delhi.
- Akçın, H. (2001). Jeoid Kavramı ve Belirleme Teknikleri Üzerine Bir İnceleme. *Niğde Üniversitesi Mühendislik Bilimleri Dergisi*, **4-1**:37-50
- 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.
- Ayala, C., Fernandez, M., Torne, M. And Pous, J. (1996). *Geophysical Journal International*. Volume 127, Issue 2: 542-544
- 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.
- Başkan, O. (2004). Gölbaşı yöresi topraklarının mühendislik, fiziksel özellik ilişkilerinde jeoistatistik uygulaması, Doktora Tezi, A.Ü, Fen Bilimleri Enstitüsü, Ankara.
- 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.
- 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.
- Blewitt G., 1993. Advances in GPS Technology for Geodynamics Investigations:in Contribution of Space Geodesy to Geodynamics: Technology Geodynamics, American Geophysical Union, Washington, 25, 195-213.
- Canan, S. (2006). Yapay Sinir ađları ile GPS Destekli Navigasyon Sistemi. Doktora Tezi, Selçuk Üniversitesi, Fen Bilimleri Enstitüsü, Konya.
- Ceylan, A., Üstün, A., Dođanalp, S., Gürses, H.B., 2011. Karayolu ve Demiryolu Projelerinde Ortometrik Yükseklik Hesabı: En Küçük Kareler ile Kollokasyon. 13. Türkiye Hairta Bilimsel ve Teknik Kurultayı. Ankara
- Cybenko, G. (1989). Approximations by superpositions of sigmoidal functions. *Mathematics of Control, Signals and Systems*, **2**: 303-314.
- Çakır, L. (2012). Ortometrik Yüksekliklerin Dolaylı Olarak GPS Gözlemlerinden Elde Edilmesinde Kullanılan Yöntemlerin İrdelenmesi. Doktora Tezi, Karadeniz Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Trabzon
- DARPA (1988). Neural Network Study, AFCEA International Press, Fairfax, VA.
- David, M., 1988. Handbook of Applied Advanced Geostatistical ore Reserve Estimation, Elsevier Science Publishing Company, Amsterdam.
- Deutsch, C.V., and Journal, A.G., (1992). Geostatistical Software Library And User's Guide, Oxford University Press, Inc., New York.
- Dodson A.H., 1995. GPS for Height Determination, *Survey Review*, 66, 256.
- 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. (2010). Modelling the spatial distribution of DEM error with geographically weighted regression: An experimental study. *Computers and Geosciences*, **36**: 34-43.
- Erol, B. (2007). Investigation on Local Geoid for Geodetic Applications, PhD Thesis, Institute of Science and Technology, İstanbul Technical University, Turkey.
- Fausett, L. (1999). Fundamentals of Neural Networks: Architectures, Algorithms and Applications. Prentice Hall, Upper Saddle River, NJ.
- Featherstone W.E., Dentith M.C., Kirby J.F., 1998. Strategies for the Accurate Determination of Orthometric Heights ferom GPS, *Survey Review*, 34, 267.
- Forsberg, R., Ses, S., Alshamsi, A. And Din, A.H. (1992). Coastal geoid improvement using airborne gravimetric data in the United Arab Emirates. *International Journal of Physical Sciences* Vol. **7(45)**: 6012-6023.
- Fotopoulos, G. (2003). An Analysis on the Optimal Combination of Geoid, Orthometric and Elipsoidal Height Data, PhD Thesis, Department of Geomatics Engineering, University of Calgary, Alberta.
- Funahashi, K. (1989). On the approximate realization of continuous mappings by neural networks. *Neural Networks*, **2**: 183-192.
- Garcia, R.V. (2002). Local Geoid Determination From GRACE Mission. Report No. 460 Dept. Of Geod. Sci., Ohio State University, Columbus.
- Graupe, D. (2007). Principles of Artifical Neural Networks. World Scientific Publishing, Singapore.
- 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.

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.

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. (1996) Yerel Jeoid Geçirilerek GPS Sonuçlarından Yükseklik Belirlemesi. *S.Ü. Müh. Mim. Fak. Dergisi*, cilt 11, sayı 2:15-21
- 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.
- 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.
- Kılıçoğlu, A., 2002, Güncelleştirilmiş Türkiye Jeoidi -1999A (TG99A), TUJK 2002 Yılı Bilimsel Toplantısı, Tektonik ve Jeodezik Ağlar Çalıştayı Bildiri Kitabı, İznik.
- Kiamehr, R. And Sjöberg, L.E. (2005). Effect of the SRTM global DEM on the determination of a high-resolution geoid model: a case study in Iran. *Journal of Geodesy*, **78**: 540-551
- Kohonen, T. (1972). Correlation matrix memories. *IEEE Transaction on Computers*, **C21-4**: 353-359.
- Konak, H, Çepni, M.S., Kurt, O. (2007) Sonlu Elemanlarla Modellenen Yerel Jeoitler Yardımıyla, Yer Kabuğu Hareketlerindeki Düşey Bileşenlerin İrdelenmesi. Earthquake Symposium. Kocaeli.
- Kotsakis, C. and Sideris, M. G. (1999). On the adjustment of combined GPS/levelling/geoid networks. *Journal of Geodesy* **73**: 412-421

- Kuhar M, Stopar B, Turk G, Ambrozjicÿ T (2001). The use of artificialneural network in geoid surface approximation. AVN 2001, pp. 22-27.
- Kurt, O., Arslan, O., Konak, H. (2007). Lokal Jeoit Modellemede Çift Aşamalı Yarı Dinamik Polinomsal Yüzey Uydurma. International Earthquake Syposium, Kocaeli.
- 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.
- 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.
- Martensson, SG., (2002). Height determination by GPS accuracy with respect to different geoid models in Sweden, FIG XXII. International Congress, Washington DC, U.S.A, April 19-26.
- 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.

- Mert, B. A. (2005). Jeostatistiksel analiz için bir bilgisayar programının geliştirilmesi ve Antalya-Akseki-Kızıltaş boksit yatağına uygulanması, Yüksek Lisans Tezi, Çukurova Üniversitesi, Fen Bilimleri Enstitüsü, Adana.
- 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.
- 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.
- 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.
- Park W., 1998. Accuracy of GPS-Derived Leveling Section Orthometric Height Difference in San Diego County, Surveying and Land Information System, California, 58,1, 31-46.

- in San Diego County, Surveying and Land Information System, California, 58,1, 31-46.
- Patan, K. (2008). Artificial Neural Networks for the Modelling and Fault Diagnosis of Technical Processes. Springer, London-New York.
- 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.
- Poulton, M.M. (2001). Computational Neural Networks for Geophysical Data Processing (Handbook of Geophysical Exploration: Seismic Exploration). Pergamon, London-New York.
- 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). Paralel 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.
- Sađırođlu, Ő., BeŐdok, E. ve Erler, M. (2003). Mühendislikte Yapay Zeka Uygulamaları-I: Yapay Sinir Ağları. Ufuk Yayıncılık, Kayseri.
- 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.
- Sutton, R. S. and Barto, A.G. (1998). Reinforcement Learning: An Introduction. MIT Press, Cambridge, MA.
- Ően, Z. (2004). Yapay Sinir Ađı 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

Tosunođlu, N.G. (2007). Mekansal İstatistikte Bulanık Uyarlamalı Ağ Yaklaşımı ile Depremi oluşturan Yer kabuđu Hareket Hızlarının Kestirimi. Doktora Tezi, Ankara Üniversitesi, Fen Bilimleri Enstitüsü, Ankara.

Trangmar B. B., Yost R. J., Wehara G., Application of Geostatistic to spatial studies of soil properties. *Advances in agronomy*, Vol. **38**: 65-91.

Turgut B., İnal C., Yiđit C.Ö., (2002), Egm 96 Jeopotansiyel Modeli, Tg 99 Türkiye Jeoidi Ve Gps/Nivelman İle Elde Edilen Jeoit Ondüasyonlarının Karşılaştırılması, Selçuk Üniversitesi Jeodezi ve Fotogrametri Mühendisliđi Öğretiminde 30. Yıl Sempozyumu , Konya

URL-1, www.ngs.noaa.gov/GEOID/geoid_def.html, What is the Geoid?, 10 Şubat 2011.

URL-2, <http://www.hgk.msb.gov.tr/urunler/jeodezikurunler.asp>, Topografik Haritalar ve Jeodezik Temel Ağlara Ait Adedi Bilgiler. 2013.

Veronneau, M., Duval, R., Huang, J. (2006). A Gravimetric Geoid Model As A Vertical Datum In Canada. *Geomatica* Vol. 60, No. **2**: 165-172

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.

Yanalak, M. (2002). Sayısal Arazi Modellerinde Yükseklik Enterpolasyonu. *Harita Dergisi*, Sayı:**128**

Yanalak, M., Baykal, O. (2001). Transformation of Ellipsoid Heights to Local Levelling Heights. *Journal of surveying Engineering, ASCE*; 127, pp. 90-103.

- Yaprak, S. (2007). Kriging Yönteminin Geoit Yüzeyi Modellemesinde Kullanılabilirliğinin Araştırılması ve Varolan Yöntemlerle Karşılaştırılması. Doktora Tezi, İstanbul Teknik Üniversitesi, Fen Bilimleri Enstitüsü, İstanbul.
- 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. (2012). Jeodezik Nokta Hız Kestiriminde Yapay Sinir Ağlarının Kullanılabilirliği. Doktora Tezi, Afyon Kocatepe Üniversitesi, Fen Bilimleri Enstitüsü, Afyonkarahisar.
- 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.
- Yılmaz, N. (2011). Türkiye İçin Farklı Yöntem ve Verilerle Belirlenen Jeoidlerin Karşılaştırılması. Doktora Tezi, Karadeniz Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Trabzon.
- Yiğit, C. Ö., 2003. Elipsoidal Yüksekliklerin Ortometrik Yüksekliğe Dönüşümünde Kullanılan Enterpolasyon Yöntemleri. Yüksek Lisans Tezi, Selçuk Üniversitesi, Fen Bilimleri Enstitüsü, Konya.
- Yurt, K. Ve Gökalp, E. (2009). Geometrik ve Gravimetrik (Gel-Gitten Bağımsız) Jeoid Modellerinin Karşılaştırılması: Trabzon Örneği. *Harita Teknolojileri Elektronik Dergisi* Cilt:1, No 1:23-31
- 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.

ÖZGEÇMİŞ

Adı Soyadı : Eray AŞIK
Doğum Yeri ve Tarihi : Ankara 15/08/1985
Yabancı Dili : İngilizce
İletişim (Telefon/e-posta) : erayasik@aku.edu.tr

Eğitim Durumu (Kurum ve Yıl)

Lise : Dr. Şerafettin Tombuloğlu Lisesi (1999-2002)
Lisans : Selçuk Üniversitesi (2002-2007)

Çalıştığı Kurum/Kurumlar ve Yıl : Afyon Kocatepe Üniversitesi Yapı İşleri Dai.
Bşk. (2009-)

Yayınları (SCI ve diğer) :--