



**T. C.**  
**KONYA TEKNİK ÜNİVERSİTESİ**  
**LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ**



**YAPAY SİNİR AĞLARI İLE YEREL JEOİT  
BELİRLEME**

**Yaşar FİDANCI**

**YÜKSEK LİSANS TEZİ**

**Harita Mühendisliği Anabilim Dalı**

**Nisan-2019**  
**KONYA**  
**Her Hakkı Saklıdır**

## TEZ KABUL VE ONAYI

Yaşar FİDANCI tarafından hazırlanan “Yapay Sinir Ağları İle Yerel Jeoit Belirleme” adlı tez çalışması 08/04/2019 tarihinde aşağıdaki jüri tarafından oy birliği ile Konya Teknik Üniversitesi Lisansüstü Eğitim Enstitüsü Harita Mühendisliği Anabilim Dalı’nda YÜKSEK LİSANS TEZİ olarak kabul edilmiştir.

### Jüri Üyeleri

#### Başkan

Prof. Dr. Ekrem TUŞAT

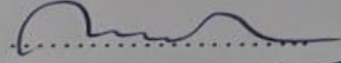
#### Danışman

Doç. Dr. R. Alpay ABBAK

#### Üye

Dr. Öğr. Üyesi Kemal YURT

### İmza



Yukarıdaki sonucu onaylarım.

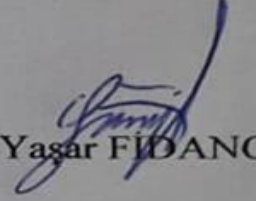
Prof. Dr. Yakup KARA  
Enstitü Müdürü

## TEZ BİLDİRİMİ

Bu tezdeki bütün bilgilerin etik davranış ve akademik kurallar çerçevesinde elde edildiğini ve tez yazım kurallarına uygun olarak hazırlanan bu çalışmada bana ait olmayan her türlü ifade ve bilginin kaynağına eksiksiz atıf yapıldığını bildiririm.

## DECLARATION PAGE

I hereby declare that all information in this document has been obtained and presented in accordance with academic rules and ethical conduct. I also declare that, as required by these rules and conduct, I have fully cited and referenced all material and results that are not original to this work.

  
Yaşar FIDANCI

## ÖZET

### YÜKSEK LİSANS TEZİ

### YAPAY SİNİR AĞLARI İLE YEREL JEOİT BELİRLEME

Yaşar FİDANCI

Konya Teknik Üniversitesi  
Lisansüstü Eğitim Enstitüsü  
Harita Mühendisliği Anabilim Dalı

Danışman: Doç. Dr. R. Alpay ABBAK

2019, 44 Sayfa

Jüri

Doç. Dr. R. Alpay ABBAK  
Prof. Dr. Ekrem TUŞAT  
Dr. Öğr. Üyesi Kemal YURT

Jeoit, fiziksel anlamlı ortometrik yükseklikler için referans yüzeyidir. Bu nedenle jeoidin yüksek hassasiyette belirlenmesi yerbilimlerinde özellikle jeodezide hayati öneme sahiptir. Uygulamada jeoit belirleme için çoğunlukla GNSS (Global Navigation Satellite Systems—Küresel Seyrüsefer Uydu Sistemleri) ve nivelman verilerini birlikte değerlendiren birçok matematiksel yüzey ve enterpolasyon teknikleri uygulayan geometrik yöntem kullanılır.

Günümüzde hızla gelişen yapay zekâ ve makine öğrenmesi teknolojileri, algoritması çok karışık problemlere insan beyni gibi davranarak çözümler üretmektedir. Bu çalışmada yapay zeka teknolojilerinden yapay sinir ağı incelenmiş, jeoit belirlemede kullanılabilirliği test edilmiştir. Bu amaçla yaklaşık 2765 km<sup>2</sup> lik yüzölçümüne sahip Belçika’da bir çalışma alanı seçilmiş ve bu alanda bulunan 326 GNSS-nivelman noktası aracılığı ile eğitim ve test verilerini değiştirerek 6 adet deney yapılmıştır. Bu noktalar çeşitli kombinasyonlar oluşturacak şekilde eğitim ve test seti olarak ayrılmıştır. Bu kapsamda yapay sinir ağı modelleri ve polinomal eğri yüzey modelleri oluşturulmuş ve karşılaştırma sonuçları üretilmiştir. Sayısal sonuçlar “Büyük Ölçekli Harita ve Harita Bilgileri Üretim Yönetmeliği” açısından bakıldığında hem homojen hem de homojen olmayan nokta dağılımında yapay sinir ağı modelinin polinomal yüzey modelinden daha iyi sonuçlar ürettiği görülmüştür.

**Anahtar Kelimeler:** Çok Katmanlı Algılayıcılar, Jeoit Belirleme, Polinomal Eğri Yüzey Uydurma, Yapay Sinir Ağları.

**ABSTRACT**

**MS THESIS**

**DETERMINATION OF LOCAL GEOID WITH ARTIFICIAL NEURAL NETWORKS**

**Yaşar FİDANCI**

**Konya Technical University  
Institute of Graduate Studies  
Department of Geomatics Engineering**

**Advisor: Assoc. Prof. Dr. R. Alpay ABBAK**

**2019, 44 Pages**

**Jury  
Assoc. Prof. Dr. R. Alpay ABBAK  
Prof. Dr. Ekrem TUŞAT  
Assist. of Prof. Dr. Kemal YURT**

Geoid is a reference surface for physical orthometric heights. Thus precise geoid determination is essential important in geosciences especially in geodesy. For the geoid determination the geometrical method that evaluates GNSS (Global Navigation Satellite Systems) together with levelling data is mostly used in practice. In order to determine geoid surface, many mathematical surfaces and interpolation techniques are applied in this method.

Today the rapidly developing artificial intelligence and machine learning technologies by behaving the human brain produce solutions to problems, which have very complex algorithms. In this study, the artificial neural network from artificial intelligence technologies was examined and also its usability was tested in the geoid determination. For this purpose a study area that covers approximately 2765 km<sup>2</sup> was selected and some tests were carried out in this area by using 326 GNSS-levelling points. These points were divided into training and test datasets in order to create various combinations. In this context, some artificial neural network models and polynomial curve surface models were yielded and comparison results were produced. According to numerical results, it was observed that models of artificial neural networks produced better results than the polynomial curve surface models in the homogenous and non-homogeneous point distributions from viewpoint of “Rules of Large Scale Map and Map Data Production”.

**Keywords:** Artificial Neural Networks, Geoid Determination, Multilayer sensors, Polynomial Curve Surface Fitting.

## ÖNSÖZ

Çalışmalarımın her safhasında yardımını esirgemeyen, yolumu aydınlatan, her türlü sabır ve fedakârlığı gösteren, beni cesaretlendiren, değerli bilgi ve görüşlerinden yararlandığım, saygı değer danışman hocam Sayın Doç. Dr. R. Alpay ABBAK'a teşekkürü bir borç bilirim.

Bugün kadar hiç desteğini esirgemeyen değerli dostum İnşaat Mühendisi Gürbüz UZUN'a teşekkür ederim.

Çalışmam süresinde gösterdikleri destek, sabır, anlayış ve fedakârlıkları için değerli eşim Yağmur FİDANCI'ya ve biricik kızım Zeynep İdil FİDANCI'ya bu tezi ithaf etmek istiyorum. Son olarak, bana çalışma azmini ve kararlılığını veren anneme ve babama da minnettar olduğumu ifade etmek isterim.

Yaşar FİDANCI  
KONYA-2019

## İÇİNDEKİLER

<b>ÖZET</b> .....	<b>vii</b>
<b>ABSTRACT</b> .....	<b>viii</b>
<b>ÖNSÖZ</b> .....	<b>ix</b>
<b>İÇİNDEKİLER</b> .....	<b>x</b>
<b>SİMGELER VE KISALTMALAR</b> .....	<b>xi</b>
<b>1. GİRİŞ</b> .....	<b>1</b>
<b>2. KAYNAK ARAŞTIRMASI</b> .....	<b>4</b>
<b>3. YÖNTEM</b> .....	<b>8</b>
3.1. Yapay Sinir Ağları .....	8
3.1.1. Yapay sinir ağlarının özellikleri .....	9
3.1.2. Yapay sinir ağları uygulama alanları .....	10
3.1.3. Yapay sinir ağlarının sınıflandırılması .....	11
3.1.4. Yapay sinir ağlarının teknik bilgileri .....	12
3.1.5. Yapay sinir hücresinin çalışma prensibi ve yapısı .....	16
3.1.6. Yapay sinir ağlarının çalışması ve test edilmesi .....	18
3.1.7. Yapay sinir ağlarında en fazla kullanılan modeller .....	19
3.1.8. XOR problemi.....	20
3.1.9. Çok katmanlı algılayıcıların yapısı .....	20
3.1.10. Çok katmanlı algılayıcıların öğrenme kuralı .....	21
3.1.11. Çok katmanlı algılayıcıların test edilmesi ve performansı .....	25
3.2. Polinomlarla Eğri Yüzey Uydurma .....	27
3.2.1. Polinomlarla eğri yüzey modelinin oluşturulması .....	27
3.2.2. Polinomlarla eğri yüzey modelinin test edilmesi.....	29
3.2.3. Polinomlarla eğri yüzey model ve dikkat edilmesi gerekenler .....	30
<b>4. SAYISAL UYGULAMA</b> .....	<b>32</b>
4.1. Çalışma Alanı .....	32
4.2. Veriler .....	33
4.3. Araştırma .....	33
<b>5. SONUÇLAR VE ÖNERİLER</b> .....	<b>38</b>
<b>KAYNAKLAR</b> .....	<b>41</b>
<b>ÖZGEÇMİŞ</b> .....	<b>44</b>

## SİMGELER VE KISALTMALAR

### Simgeler

f	: Aktivasyon fonksiyonu
w	: Bağlantı ağırlığı
$\lambda$	: Boylam
y	: Çıktı değeri
$\varphi$	: Enlem
b	: Eşik, değer
x	: Girdi değeri
$\varepsilon$	: Hata (fark)
$\alpha$	: Momentum katsayısı

### Kısaltmalar

ART	: Adaptif Rezonans Teori
ÇKA	: Çok Katmanlı Algılayıcı
EGM96	: Earth Gravitational Model 1996
EGM08	: Earth Gravitational Model 2008
GNSS	: Global Navigation Satellite System
GYSA	: Geri Yayılımlı Yapay Sinir Ağları
KOH	: Karesel Ortalama Hata
LVQ	: Lineer Vektör Kuantizasyonu
TUTGA	: Türkiye Ulusal Temel GPS Ağı
WGS84	: World Geodetic System 1984
YSA	: Yapay Sinir Ağları



## 1. GİRİŞ

Jeodezi, üç boyutlu zaman değişkenli uzayda yerin gravite alanını da hesaba katarak fiziksel yeryüzünün ölçülmesi, haritaya aktarılması ile uğraşan bir bilim dalıdır. Fiziksel jeodezinin temel amacı gravite alanını ve onun eşpotansiyel yüzeylerinden biri olan jeoidin belirlenmesidir. Jeoid matematiksel olarak ifade edilemeyen belirli bir model veya algoritma ile kesin olarak açıklanamayan bir yüzey olarak tanımlanabilir. Yüksekliğin ve derinliğin referans yüzeyi olduğu için jeoid, jeodeziciler için hayati öneme sahiptir.

Yükseklik kavramı en yalın haliyle yeryüzündeki bir noktanın başlangıç yüzeyiyle ilişkisi olarak ifade edilebilir. Bu ilişki,

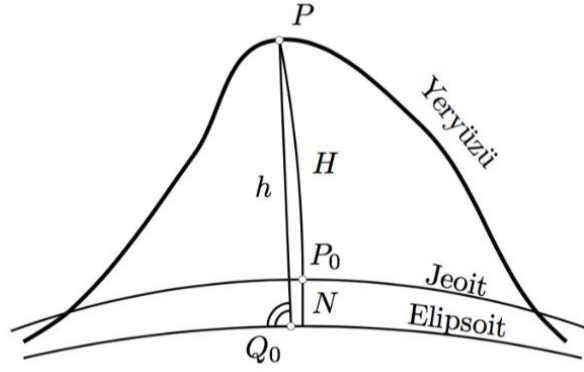
- yalnızca fiziksel,
- yalnızca geometrik,
- hem fiziksel hem geometrik,

anlamı olabilir. Ancak mühendislik uygulamalarından fiziksel anlamı yükseklik sistemleri kullanılmaktadır. Bunun nedeni akışkanların hareket yönünün doğrudan gravite alanı ile ilişkili olmasıdır. Başka bir deyişle altyapı ve mühendislik hizmetlerinin doğru bir şekilde gerçekleşebilmesi için gravite alanı ile ilişkili yükseklik sistemleri kullanılmalıdır (Abbak, 2017).

Gelişen teknolojilerle birlikte GNSS (Global Navigation Satellite Systems—Küresel Seyrüsefer Uydu Sistemleri) ortaya çıkmış ve bu sistemlerle birlikte yüksek doğrulukta konum bilgileri elde edilmeye başlanmıştır. GNSS sistemlerinin sağladığı yükseklik bilgisi mühendislik uygulamalarında ihtiyaç duyulan türden bir fiziksel yükseklik olmayıp yalnızca geometrik anlam içermektedir. Geometrik yükseklikten  $h$  fiziksel yüksekliğe  $H$  geçiş

$$H = h - N \quad (1.1)$$

eşitliği ile sağlanabilmektedir. Eşitliğin geometrik gösterimi Şekil 1.1’de verilmiştir.



Şekil 1.1 Ortometrik ve elipsoidal yükseklik arasındaki ilişki (Abbak, 2017)

Yukarıdaki (1.1) eşitliğiyle geometrik yükseklikten fiziksel yüksekliğe geçilebilecektir. Buradaki en önemli husus jeoit yüksekliğinin (jeoidin) amaca uygun doğrulukta belirlenmesidir. Doğruluk bakımından ele alındığında GNSS'ten üretilen elipsoidal yüksekliğin doğruluğu 1 cm, jeoit yüksekliğinin doğruluğu 1 cm olursa, hata yayılma kuralına göre bu yöntemle elde edilen ortometrik yüksekliğin doğruluğu yaklaşık 1.41 cm olacaktır. Bu seviye neredeyse tüm mühendislik uygulamalarında yeterlidir. Bu nedenle günümüzdeki hedef 1 cm doğruluklu jeoit modelinin belirlenmesidir.

Yüksek doğruluklu jeoit belirleme çalışmaları halen günümüzde araştırma konularının başında gelmektedir. Jeoidi modellemek için birçok yüzey ve enterpolasyon yöntemleri uygulanmış ve bu matematiksel yöntemlerle jeoit yüzeyi gerçeğe en yakın şekilde modellenmeye çalışılmıştır. Şimdiye kadar yapılan çalışmalar kısaca;

- polinomal yöntem,
- multikvadrik enterpolasyon yöntemi,
- ağırlıklı ortalama ile enterpolasyon yöntemi,
- sonlu elemanlar yöntemi,
- kollokasyon yöntemi,
- bulanık çıkarım sistemleri,
- radyal tabanlı fonksiyonlar ile yüzey modelleme yöntemi,
- Kriging enterpolasyon yöntemi,

şeklinde sıralanabilir.

Bu yöntemlere ek olarak gelişen yapay zekâ teknolojisiyle makine öğrenmeleri yapılabildiği, makinelerin insanların beyin fonksiyonlarını taklit ederek olaylar arasında neden-sonuç ilişkisi kurabildiği görülmüştür. Dahası girdilerden yola çıkarak öngörü ve

tahminler yapabilmektedir. Ayrıca deęişen şartlar altında öğrenmeye devam etmekte ve yeni duruma kendilerini adapte edebilmektedir. Bu teknolojiden faydalanılarak yukarıda bahsettiğimiz gibi jeoit yüksekliğinin yüksek doğrulukta tahmin edilmesi yerin fiziksel anlamlı yüksekliklerinin bilinmesinde çok büyük önem arz etmektedir.

Bu çalışmada popülerliği devamlı artmakta olan yapay zekâ teknolojisi makine öğrenmesi gerçekleştirilecek olup jeoit yüksekliğinin tahmini istenecek, bu sonuçlar test edilecek ve sonuçlar polinomal yöntemle karşılaştırılarak irdelenecektir. Makine öğrenme teknolojilerinden ileri beslemeli hata geri yayımlı yapay sinir ağları ile polinomal eğri yüzey uydurma yöntemi ile karşılaştırılmış eğitim nokta verileri kademeli olarak azaltılarak modellerin nasıl etkilendięi irdelenmiş, ayrıca homojen ve homojen olmayan nokta dağılımında yöntemlerin ürettięi modellerin doğruluęu araştırılmıştır. Bu yönüyle ele alındığında bu çalışmanın öncekilere göre farklılığını ifade etmektedir. Sayısal sonuçlar yapay sinir ağlarının her türlü veri yoğunluęunda polinomal yöntemden çok daha iyi doğruluklar ürettiğini göstermektedir. Son olarak yapay sinir ağlarının gündelik kullanımına yönelik görüş ve öneriler sunulmuştur.

## 2. KAYNAK ARAŞTIRMASI

Literatürde birçok çalışmada makine öğrenmesi ve yapay zekâ teknolojileri kullanılarak jeoit belirleme üzerine çalışmalar yapılmıştır. Çalışmalar genel olarak yüzey uydurma ve enterpolasyon yöntemleri ile bu yöntemlere alternatif olabilecek yapay zekâ teknolojilerinin ürettiği modellerin sonuçlarının karşılaştırılması niteliğindedir.

Konya bölgesinde yapılan bir çalışmada yapay sinir ağları yardımı ile elipsoidal yüksekliklerden ortometrik yükseklikler elde edilmiştir. Eğitim ve test seti olarak ayrılan verilerden, test verilerinin standart sapması  $\pm 4.67$  cm olduğu, Büyük Ölçekli Harita ve Harita Bilgileri Üretim Yönetmeliği (BÖHHBÜY) sınırları içinde kaldığı görülmüştür. Jeoit belirlemede yapay sinir ağlarının kullanılabilceği sonucuna varılmıştır (Çorumluoğlu vd., 2005).

Başka bir çalışmada İstanbul ilinde jeodezik altyapı oluşturmak amacı ile İstanbul Teknik Üniversitesi ile yürütülen bir projede üretilen 650 noktadan Türkiye Ulusal Düşey Kontrol Ağı içerisinde 453 adet nokta kullanılarak uygulama gerçekleştirilmiştir. Bu veriler ile yapay sinir ağları ve polinomal yöntem kullanılarak jeoit modelleri belirlenmiş ve modellerin ürettikleri sonuçlar karşılaştırılmıştır. Bu noktalardan 353 tanesi eğitim için kullanılırken 100 tanesi test verisi için ayrılmıştır. Yapay sinir ağları ile oluşturulan modelde test verilerinden elde edilen Karesel Ortalama Hata (KOH)  $\pm 15.62$  cm olarak bulunurken polinomal yöntemde ise test verilerine ait KOH  $\pm 21.34$  cm olarak hesaplanmıştır. Yapay sinir ağlarının daha başarılı sonuç ürettiği ortaya konmuştur (Kutoğlu, 2006).

Bir diğer çalışmada Brezilya'nın Rio dos Sinos'un Hidrolojik Havzasında yapılmış, veriler SIRGAS jeoit modeli aracılığı ile çalışma bölgesinde 5 km x 5 km karelej oluşturacak şekilde 314 adet simülasyon noktası üretilmiştir. Çalışma alanı içerisinde rastgele 8 adet noktaya GNSS ve nivelman ölçü yöntemleri kullanılarak noktalara ait elipsoidal ve ortometrik yükseklikleri belirlenmiş bu noktalara ait jeoit yükseklikleri hesaplanmıştır. Bu bölgede MAPGEO2004 programı ve yapay sinir ağlarının ürettiği sonuçlar kıyaslanmak suretiyle yapay sinir ağlarının ve yazılımın ürettiği değerlerin üstünlüğü araştırılmıştır. Çalışmadaki 8 adet test noktasında yapay sinir ağlarının ürettiği KOH  $\pm 8.9$  cm iken MAPGEO2004 ürettiği KOH ise  $\pm 79.0$  cm olduğu görülmüştür. Bu durum o bölge için yapay sinir ağlarının üstünlüğünü ortaya koymuştur (Veronez, 2006).

Kocaeli İli sınırları içerisinde yapılan bir çalışmada WGS84 datumunda EGM96 modelinden üretilen yaklaşık 107 km genişliğinde 80 km boyunda bir alanda simülasyon verileri kullanılarak uygulama yapılmıştır. Çalışmada yapay sinir ağları ile polinomal eğri yüzey uydurma yöntemleri kullanılarak analizler yapılmıştır. Polinomal yüzey uydurma ile hesaplanan jeoit yükseklikleri ile EGM96 modeline göre hesaplanan yükseklik değerleri arasındaki farkların standart sapma değeri  $\pm 2.05$  cm hesaplanmış, yapay sinir ağları yöntemi ile üretilen yüksekliklerle EGM96 arasındaki farkın standart sapması ise  $\pm 1.39$  cm olduğu görülmüştür. Yapay sinir ağlarının daha başarılı sonuç ürettiği anlaşılmıştır. Sonuçlarda yapay sinir ağlarının, polinomal yöntemle oranla çokta belirgin bir doğruluk artışı sağlamadığı çalışma bölgesinin küçük olduğu jeoit yüzeyinin düzgün bir yüzey olduğunun kabulü ile polinomal yöntemle yakın bir sonuç ürettiği kanısına varılmıştır (Arslan vd., 2007).

Afyonkarahisar bölgesinde yapılan bir çalışmada  $38^{\circ}26' < \phi < 38^{\circ}42'$  ve  $30^{\circ}23' < \lambda < 30^{\circ}34'$  coğrafi sınırlar arasında kalan 16 km eninde 30 km boyunda bir alanda geri yayımlı yapay sinir ağları ile diğer enterpolasyon ve eğri yüzey uydurma yöntemlerinden Kriging, ters mesafe ağırlıklandırma, modifiye Shepard, radyal fonksiyon, lokal polinomal ve polinomal yöntemleri kullanılarak kıyaslama yapılmıştır. Uygulamada TUTGA (Türkiye Ulusal Temel GPS Ağı) noktalarından faydalanılmıştır. Uygulama alanında bulunan 38 adet noktadan çalışma alanına homojen olarak dağılmış olan 14 tanesi eğitim noktası olarak, kalan 24 tanesi ise test noktası olarak ayrılmıştır. Geri yayımlı yapay sinir ağlarında optimum çözüm için farklı iterasyon sayısında çözümler yapılarak iterasyon sayısının çözüme etkisi görülmüş ve yöntemlere göre çözümler gerçekleştirilerek sonuçlardan üretilen KOH kıyaslanmıştır. Çözümlere göre eğitim ve test verilerinin KOH hesaplanmış (Çizelge 2.1) bu sonuçlar ışığında yapay sinir ağlarının en iyi sonuç verdiği görülmüş ve yapay sinir ağlarının kullanılması önerilmiştir (Güllü ve ark., 2011b).

**Çizelge 2.1** Çalışma sonuçları (cm)

	GYRSA	Kriging Yöntemi	Ters Mesafe Ağırlıklandırma Yöntemi	Modifiye Shepard Yöntemi	Radyal Fonksiyon Yöntemi	Lokal Polinomal Yöntem	Polinomal Yöntem
Eğitim KOH	1.85	3.88	2.44	2.42	2.39	2.45	2.36
Test KOH	2.04	4.89	2.69	2.66	2.61	2.46	2.43

Bir yüksek lisans tez çalışmasında ise Afyonkarahisar ili ve çevresindeki illeri kapsayan yaklaşık 360 km genişliğinde 340 km uzunluğundaki bir çalışma alanında yapılan uygulamada yapay sinir ağları ile kriging yöntemi kıyaslanmıştır. Uygulama verileri Türkiye Hibrit Jeoit Modeli-2009'da kullanılan toplam 2741 adet GNSS-Nivelman noktasından çalışma alanını kapsayan 86 tanesi ile gerçekleştirilmiştir. Bu çalışmada üç ayrı deney yapılmış (Çizelge 2.2). Çizelgeye göre yapay sinir ağının genel olarak daha iyi sonuç ürettiği görülmüştür (Aşık, 2013).

**Çizelge 2.2** Çalışma sonuçları (cm)

Eğitim Seti Adet	Test Seti Adet	YSA Test Veri KOH	Kriging Test Veri KOH
36	50	18	20
46	40	17	18
56	30	15.3	15.2

Başka bir çalışmada ise ileri beslemeli yapay sinir ağları, bulanık mantık çıkarımı, polinomal yüzey uydurma ve multikvadrik enterpolasyon yöntemleri karşılaştırılmıştır. Uygulama verisi olarak,

$$z(x,y) = \left( 0.75e^{\left[ \frac{\left( \frac{9x-2}{100} \right)^2 + \left( \frac{9y-2}{100} \right)^2}{4} \right]} + 0.75e^{\left[ \frac{\left( \frac{9x+1}{100} \right)^2 - \frac{9y+1}{100} \right]} + 0.50e^{\left[ \frac{\left( \frac{9x-7}{100} \right)^2 + \left( \frac{9y-3}{100} \right)^2}{4} \right]} - 0.2e^{\left[ -1 + \left( \frac{9x-4}{100} \right)^2 - \left( \frac{9y-7}{100} \right)^2 \right]} \right) * 50 \quad (2.1)$$

eşitliğindeki yüzey kullanılmıştır (Franke, 1979). Bu modelden rastgele üretilmiş 100 m genişliğinde 100 m uzunluğunda bir alanda 110 adet nokta belirlenmiş, 80 adeti eğitim, 30 adeti test verisi olarak kullanılmıştır. Uygulamada yöntemlerin karesel ortalama hataları; polinomal yöntem 86.0 cm, multikvadrik yöntem 70.0 cm, yapay sinir ağları 55.0 cm, bulanık çıkartım 52.0 cm olarak kestirim yapmıştır. Yapay sinir ağları ve bulanık çıkartımın, polinomal ve multikvadrik yöntemden daha iyi sonuçlar verdiği görülmüştür (Çakır, 2015).

Son olarak, yapılan bu çalışmada yapay sinir ağları ile verilen noktaların gravite değerlerinin hesaplanması istenmiştir. Bu çalışma için Amerika Birleşik Devletleri, Texas, Oklahoma, Arkansas, New Mexico, Kansas ve Colarado eyaletlerinde bulunan 23 adet gravite istasyonuna ait ölçü değerleri kullanılmış olup, bu değerlerin 13 tanesi oluşturulan yapay sinir ağının eğitim için, kalan 10 tanesi de ağın test için kullanılmıştır. Ayrıca 10 adet test noktasının gravite değerleri EGM08 modelinden de üretilmiştir. Geri yayımlı yapay sinir ağları ile EGM08 modeli kıyas niteliğindedir. Yapay sinir ağlarının ürettiği sonuçların KOH  $\pm 33.432$  mgal iken EGM08 modeline göre üretilen

sonuçların KOH  $\pm 37.555$  mgal olduğu görülmüştür. Elde edilen sonuçların birbirine yakın olmasına karşın yapay sinir ağlarının daha iyi sonuç ürettiği sonucuna varılmıştır (Turgut, 2016).

Jeoit ve gravite alanı belirlemenin yanı sıra yapay sinir ağlarının özelliği gereği doğrusal olmayan, gürültülü ve karmaşık verilere uygulanabiliyor olması nedeniyle birçok haritacılık faaliyetlerinde de kullanılmıştır. Bunlardan bazıları;

- deformasyon analizleri (Neuner, 2010),
- yer dönüklük parametrelerinin kestirimi (Liao ve ark., 2012),
- uyumsuz ölçülerin tespiti (Güllü ve Yılmaz, 2010),
- datum transformasyonu ve koordinat dönüşümü (Güllü ve ark., 2011c; Yılmaz ve Güllü, 2011),
- jeodezik ağlarda hız alanının modellenmesi (Güllü ve ark, 2011a),
- GPS tam sayı belirsizliğinin çözümü (Lei ve ark., 2010),
- fotogrametrik veya uzaktan algılama verilerinin yorumlanması (Kavzoğlu, 2009),
- tarihi haritaların konumlandırılması ve ölçeklendirilmesi (Yılmaz ve Güllü, 2010),
- sayısal arazi modeli uygulamaları (Bandara ve ark., 2011),
- uzaktan algılama görüntülerinin sınıflandırılması ve onarımı (Han ve ark., 2011),
- coğrafi bilgi sistemleri uygulamaları (Junjie ve ark., 2010),
- taşınmaz mal değerlendirmesi (Peterson ve Flanagan, 2009),

olarak sıralanabilir. Çalışmalarda yapay sinir ağları ile daha iyi sonuçlar üretilmiş, bir seçenek olarak kullanılmıştır.

### 3. YÖNTEM

Bu bölümde sayısal uygulamada kullanılacak yapay sinir ağları ve polinomal yöntemin temel teorik bilgileri verilerek yöntemlerin özellikleri, çalışma prensipleri ve kullanım alanlarından bahsedilmektedir.

#### 3.1. Yapay Sinir Ağları

Yapay sinir ağları insan beyninin özelliklerinden olan öğrenme yoluyla yeni bilgi üretme ve keşfetme gibi yetenekleri herhangi bir yardım alamadan otomatik olarak gerçekleştirmek amacıyla geliştirilen bilgisayar sistemleridir (Öztemel, 2016). Daha genel bir tanım yapmak gerekirse insan beyninin öğrenmeyi sağlayan sinir hücrelerini model alarak hayatta örnekleri, olayları ve sonuçlarını kullanarak olayları öğrenebilen ve çevresel etkilere karşı üretilecek tepkileri belirleyen bilgisayar sistemi olduğu söylenebilir.

Yapay sinir ağlarının kısaca tarihçesi insanların nörobiyoloji konusuna ilgi duyması ve elde ettikleri bilgileri bilgisayar bilimine uygulaması ile başlamaktadır (Öztemel, 2016). Bu anlamda yapay sinir ağlarına öncülük yapabilecek kaynaklar insan beyninin fonksiyonunu anlatan ilk eser 1870 yılında yayınlanmıştır. Bu aşamadan sonra 1940 yıllara çeşitli çalışmalar yapılsa da bu çalışmalar akademik anlam taşımamaktadır. 1940 yılından sonra Hebb, McCulloch ve Pitts gibi bilim adamları yapay sinir ağlarının temellerini atacak eserler vermişlerdir (Öztemel, 2016). Yapay sinir ağlarının gelişimini iki kısımda incelenebilir. Yapay sinir ağları tarihinde 1970 tarihi çok önemli bir dönüm noktasını teşkil etmektedir. 1970 den önceki çalışmalarda yapay sinir ağları yalnızca doğrusal problemlere çözüm üretebilirken bu tarihten sonra xor probleminin çözümü ile birlikte yapay sinir ağlarının doğrusal olmayan problemlere de çözümler üretebildiği görülmüş ve bu zamandan sonra yapay sinir ağları hızla gelişmiştir.

Yapay sinir ağları kullanmanın amacı bir problemi herhangi matematiksel modelle tasvir edilemeyen veya çok karmaşık algoritmalara sahip problemlerin çözümü için kullanılır. Dolayısı ile çevreden gelen etkileri okuyabilen bu etkilerle öğrenen ve bu etkilere tepki veren sistemlerdir. İnsan beyninin fonksiyonel özelliklerine benzer şekilde,

- öğrenme,
- ilişkilendirme,
- sınıflandırma,



- genelleme,
- optimizasyon,

görevlerini başarıyla yapmaktadır.

Teknik olarak da yapay sinir ağlarının en temel görevi, kendisine gösterilen örneklere karşılık gelebilecek bir sonuç belirlemektir. Bunu yapabilmesi için, yapay sinir ağının örnekler ile eğitilerek genelleme yapabilecek yeteneğe kavuşturulur. Bu genelleme ile benzer olaylara karşılık gelen çıktı setleri belirlenir (Öztemel, 2016).

### 3.1.1. Yapay sinir ağlarının özellikleri

Yapay sinir ağlarının özelliklerini aşağıdaki gibi sıralanabilir (Öztemel, 2016):

- Yapay sinir ağları ile makine öğrenmesi gerçekleşir.
- Programları çalışma stili bilinen programlama yöntemlerine benzememektedir.
- Yapay sinir ağları örnekleri kullanarak öğrenir.
- Güvenle çalışabilmesi için eğitimi ve performansları test edilmesi gerekir.
- Görülmemiş örnekler hakkında bilgi üretebilir.
- Algılamaya yönelik olaylarda kullanılabilir.
- Örüntü ilişkilendirme ve sınıflandırma yapabilir.
- Örüntü tamamlama gerçekleştirebilir.
- Kendi kendini organize etme ve öğrenebilme yeteneği vardır.
- Eksik bilgi ile çalışabilir.
- Hata toleransına sahiptir.
- Belirsiz ve tam olmayan bilgileri işleyebilir.
- Dereceli bozulma gösterir.
- Dağınık bir belleğe sahiptir.
- Sadece nümerik bilgilerle çalışabilmektedir.

Bu maddelerin yanında oluşturulan modele göre farklı özelliklerden de bahsetmek mümkün olabilir. Özelliklerden de anlaşılacağı üzere geleneksel yazılım teknolojileri ile çözüm bulunamayan problemlere yapay sinir ağlarıyla çözüm bulunabileceği görülmektedir. Geleneksel yöntemler ve algoritmalar, eksik ve bozulmuş verilerle sonuç üretmesi beklenemez.

Yapay sinir ağlarının bu özellikleri yanında olumsuz yönlerinden bahsetmek gerekirse;

- donanıma bağlı çalışır,

- probleme uygun ağ yapısının belirlenmesi genellikle deneme-yanılma yoluyla ile yapılmaktadır,
- yapay sinir ağının proses elemanları sayısı, katman sayısı, öğrenme katsayıları gibi değerleri belirlenmesinde belirli bir kural yoktur,
- sadece nümerik bilgilerle çalışmaktadır,
- ağın eğitiminin ne zaman biteceğine dair geliştirilmiş bir yöntem yoktur, bunların dışında en önemli eksikliği ağın davranışlarının açıklanmamasıdır.

### 3.1.2. Yapay sinir ağları uygulama alanları

Yapay sinir ağları ile nelerin yapılabileceği konusunda bir sınırlama yapmak çok zordur. Genel olarak bakıldığında zaman örnekler verilebilen tüm konular hakkında yapay sinir ağları kurulabilir. Ancak çözüm aranan problemlerde yapay sinir ağları diğer çözüm yollarından daha avantajlı olduğu durumlarda kullanılmalıdır. Yapay sinir ağları kullanırken şu iki maddeyi sağlaması önemlidir:

- sadece yapay sinir ağları ile konuya pratik çözüm üretmek mümkün mü?
- başka çözüm yolları olmasına rağmen yapay sinir ağları daha pratik ve etkin bir çözüm getirebiliyor mu?

Başarılı uygulamalar incelendiğinde yapay sinir ağlarının, doğrusal olmayan çok boyutlu, gürültülü, karmaşık, kesin olmayan, eksik, kusurlu, hata olasılığı yüksek, sensör verilerinin olması ve problemin çözümü için özellikle bir matematik modelin ve algoritmanın bulunmaması halinde yaygın olarak kullanıldıkları görülmektedir (Öztemel, 2016). Bu amaçlarla geliştirilmiş ağlar genel olarak bazı özellikleri yerine getirmektedir. Bunlar;

- olasılık fonksiyon kestirimleri,
- sınıflandırma,
- ilişkilendirme ve örüntü eşleştirme,
- zaman serileri analizleri,
- sinyal filtreleme,
- veri sıkıştırma,
- örüntü tanıma,
- doğrusal olmayan sinyal işleme,
- doğrusal olmayan sistem modelleme,
- optimizasyon,


- zeki ve doğrusal olmayan kontrol, şeklinde özetlenebilir.

### 3.1.3. Yapay sinir ağlarının sınıflandırılması

Yapay sinir ağlarını sınıflandırırken genel olarak iki tür sınıflandırmadan bahsedilebilir. Bunlar yapay sinir ağlarının öğrenme stratejileri ve yapay sinir ağlarının nöronlarının bağlantı şekilleridir.


Yapay sinir ağları öğrenme stratejilerini kendi içerisinde; öğretmenli öğrenme, destekleyici öğrenme, öğretmensiz öğrenme ve karma stratejiler olarak sıralanmak mümkündür. Öğretmenli öğrenme girdilere karşı bir çıktının olduğu öğrenme stratejisidir. Bunlardan en önemlisi ve en çok kullanılanı çok katmanlı algılayıcılarıdır. Destekleyici öğrenme stratejisinde ise girdi setine karşılık olarak girdinin karşılığı olan değerler değil üretilen sonucun doğru veya yanlış olduğu söylenerek öğrenme sağlanır. Bu ağlara örnek olarak LVQ (Linear Vector Quantization) ağları örnek gösterilebilir. Öğretmensiz öğrenmede girdilere karşı olarak herhangi bir çıktı gösterilmeksizin ağın çıktı üretmesi beklenir. Burada girdi verileri arasındaki ilişki kullanılarak öğrenme sağlanır. Sınıflandırma yapmakta kullanılır. Art ağları bunlara örnek verilebilir. Karma stratejide kısmen öğretmenli kısmen öğretmensiz olarak öğrenme yapan ağlar kastedilmektedir. Bunlara örnek olarak radyal tabanlı yapay sinir ağları ve olasılık tabanlı yapay sinir ağları örnek verilebilir.

Yapay sinir ağlarının nöronlarının bağlantı şekillerine göre ise ileri beslemeli yapay sinir ağları ve geri beslemeli yapay sinir ağları sınırlandırılır. İleri beslemeli yapay sinir ağları girdiden çıktıya doğru bir veri iletim şekli vardır (Şekil 3.1). Bu ağlar statik bir hafızaya sahiptir.



Şekil 3.1. İleri beslemeli yapay sinir ağları (Yılmaz, 2012)

Geri beslemeli yapay sinir ağlarında ise ara ve çıktı katmanlarındaki üretilen çıktı değerleri hem ileri yönlü hem de gerideki nöronlara girdi olarak gönderilir (Şekil 3.2). Bundan dolayı dinamik bir hafıza yapısına sahiptir. Çıktı beklemeksizin öğrenme devam etmektedir.




Şekil 3.2. Geri beslemeli yapay sinir ağları (Yılmaz, 2012)

### 3.1.4. Yapay sinir ağlarının teknik bilgileri

Yapay sinir ağları önceki bölümlerde de bahsedildiği üzere insan beynin sinir yapısı düşünülerek inşa edilmiş ve modeller geliştirilmiştir. İnsan beyni de birçok sayıda sinir hücresinin bir koleksiyonudur. Bir sinir ağı milyarlarca sinir hücresinin bir araya gelerek sinir ağını oluşturmaktadır. Oluşturulan bu sinir ağları sayesinde sinir

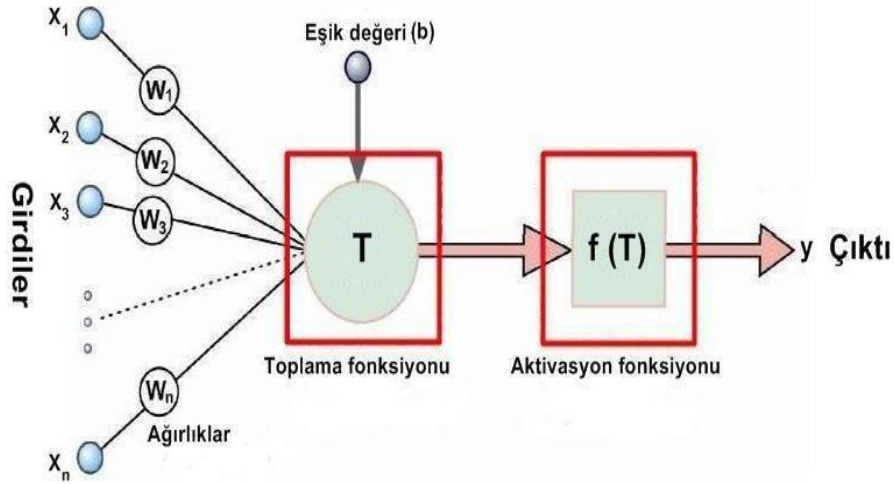
hücrelerinin birbirleri arasındaki bağlantılar sayesinde beyin, fonksiyonlarını yerine getirir (Şekil 3.3).



Şekil 3.3. Biyolojik Sinir Hücresinin Yapısı

Şekil 3.3’de gösterildiği gibi biyolojik sinir hücresi *snapsler*, *soma*, *axon* ve *dentrite*’lerden oluşmaktadır. Sinapslar diğer hücreler arası bağlantılar olarak görülebilir. Sinapslardan alınan sinyaller akson aracılığı ile somalara iletilir. Somanın içinde işlem gören sinyaller denritler aracılığı ile diğer hücrelerin sinapslarına iletilerek diğer sinir hücrelerine iletilir. Böylece insani fonksiyonlarımızı gerçekleştirmemizi sağlayan sinir ağları oluşturulur. Yapay sinir ağları ile bu fonksiyonların bilgisayarlara kazandırılmaya çalışılmaktadır.

Bir yapay sinir ağında bilgileri oluşturan, bilgileri üreten, bir bilgiden başka bir bilgiyi türeten ve bu bilgileri çevren alan, ürettiği veri çıktı olarak, sonuç olarak çevreye veya diğer bir işlem(proses) elemanına veren mekanizma olarak tanımlanabilir. Yapay sinir hücreleri mühendislikte işlem(proses) elemanları olarak adlandırılmaktadır (Şekil 3.4).



Şekil 3.4. Yapay Sinir Hücresinin Yapısı (Kaftan, 2010)

**Girdiler:** Dış dünyadan (örneklerden) gelen verilerdir. Örnekleri öğrenmesi için verilen örnekler tarafından belirlenen en temel verilerdir. Bu bilgiler en temelinde dış dünyadan gelebileceği gibi başka bir işlem(proses) elemanından da gelebilir.

**Ağırlıklar:** Ağırlıklar yapay sinir hücresine giren bir bilginin önemini gösterir. Bir ağırlığın büyük veya küçük olması o verinin önemli veya önemsiz olduğunu göstermez. Ancak bir ağırlık değerinin sıfır olması ağ için çok önem arz edebilir. Verinin ağ için önemli bir etkisinin olmadığını gösterir. Ağırlıkların pozitif veya negatif olması ise o ağı sonucu pozitif veya negatif yönde etkilediğini gösterir.

**Eşik değeri:** Yapay sinir ağlarında ara katman veya çıktı katmanlarının çıktı değerlerinin sıfır olmasını önlemek için kullanılır.

**Toplama fonksiyonu:** Toplama fonksiyonu olarak adlandırılan ifade bir yapay sinir ağı hücresine giren ağırlıklandırılmış net girdinin hesaplanması için kullanılan fonksiyonları ifade eder. Yapay sinir ağlarında en yaygın olarak kullanılan fonksiyon ağırlıklı toplam fonksiyonu,

$$NET = \sum_i^n G_i A_i \quad (3.1)$$

ile ifade edilir. Bu fonksiyondaki  $G$  girdileri  $A$  ağırlıkları ifade etmektedir. Yapay sinir ağlarında toplama fonksiyonu olarak ağırlıklı toplama fonksiyonu kullanmak zorunlu değildir. Tasarlanacak modele göre farklı fonksiyonlar kullanılabilir. Bazı durumlarda ağırlıklı toplam önemli olurken bazı durumlarda girdi sayıları önemli olabiliyor. Bu tasarımcının öngörüsüne bağlı bir durumdur. Hangi modelde hangi toplama fonksiyonunun kullanılacağıyla ilgili bir yargı yoktur. Tamamen tasarımcının öngörüsü

veya deneme yanılma yoluyla bulunmaktadır. Çizelge 3.1’de bazı toplama fonksiyonları gösterilmiştir.

**Çizelge 3.1.** Toplama fonksiyonu örnekleri (Öztemel, 2016).

Net giriş	Açıklama
Çarpım $NET \text{ GİRĐİ} = \prod_i G_i A_i$	Ağırlık değerleri girdiler ile çarpılır ve daha sonra bulunan değerler birbirleri ile çarpılarak net girdi hesaplanır
Maksimum $NET \text{ GİRĐİ} = \text{Max}(G_i A_i), i = 1 \dots N$	N adet girdi ağırlıklarıyla çarpıldıktan sonra içlerinden en büyüğü net girdisi olarak kabul edilir.
Minimum $NET \text{ GİRĐİ} = \text{Min}(G_i A_i), i = 1 \dots N$	N adet girdi ağırlıklarıyla çarpıldıktan sonra içlerinden en küçüğü net girdisi olarak kabul edilir.
Çoğunluk $NET \text{ GİRĐİ} = \sum_i \text{sgn}(G_i A_i)$	N adet net girdi içinden ağırlıklar ile çarpıldıktan sonra pozitif ve negatif olanların sayısı bulunur. Büyük sayı hücrenin net girdisi olarak kabul edilir.
Kümülatif toplam $Net(eksi) + \sum_i (G_i A_i)$	Hücreye gelen bilgiler ağırlıklı olarak toplanır ve hücreye önce gelen bilgilere eklenerek hücrenin net girdisi bulunur.

**Aktivasyon fonksiyonu:** Temel hesaplama birimi işleminin yapan ve sonucunda çıktının değerinin belirlendiği fonksiyonlardır. Aktivasyon fonksiyonunda da toplama fonksiyonu gibi temel bir formül yoktur. Yapay sinir ağlarının en yaygın olarak kullanılan modeli olan çok katmanlı algılayıcılarda sigmoid fonksiyonu,


$$F(NET) = \frac{1}{1+e^{-NET}} \quad (3.2)$$

kullanılmaktadır. Buradaki NET, işlem(proses) elemanına giren NET girdi değeridir. Aktivasyon fonksiyonların kullanımında belirli bir yöntem yoktur. Aktivasyon fonksiyonu belirlenirken yine tasarımcının kişisel öngörüsü ve deneme-yanılma yöntemi belirleyicidir. Bazı modellerde türevi alınabilir fonksiyonları şart koşmuştur. Yapay sinir ağlarında literatürde yaygın olarak kullanılan; sigmoid, hiperbolik, tanjant, lineer, basamak, Gauss ve multiküadratik aktivasyon fonksiyonları (Graupe, 2007; Patan, 2008; Beale, et al. 2010) Çizelge 3.2’de verilmiştir.

**Çizelge 3.2.** Başlıca aktivasyon fonksiyonları

Aktivasyon fonksiyonun adı	Fonksiyon
Sigmoid	$F(NET) = \frac{1}{(1 + e^{-NET})}$
Hiperbolik Tanjant	$F(NET) = \frac{(e^{NET} + e^{-NET})}{(e^{NET} - e^{-NET})}$
Lineer	$F(NET) = NET$
Basamak	$F(NET) = \begin{cases} 1 & \text{Eğer } NET > \text{Eşik DEĞER} \\ 0 & \text{Eğer } NET < \text{Eşik DEĞER} \end{cases}$

Gauss	$F(NET) = e^{-\left[\frac{(NET-C)^2}{\sigma^2}\right]}$
Multi Kuadratik	$F(NET) = \frac{\sqrt{r^2 + (NET - C)^2}}{r}$



Şekil 3.5. Aktivasyon fonksiyonlarının grafikleri (Yılmaz, 2012)

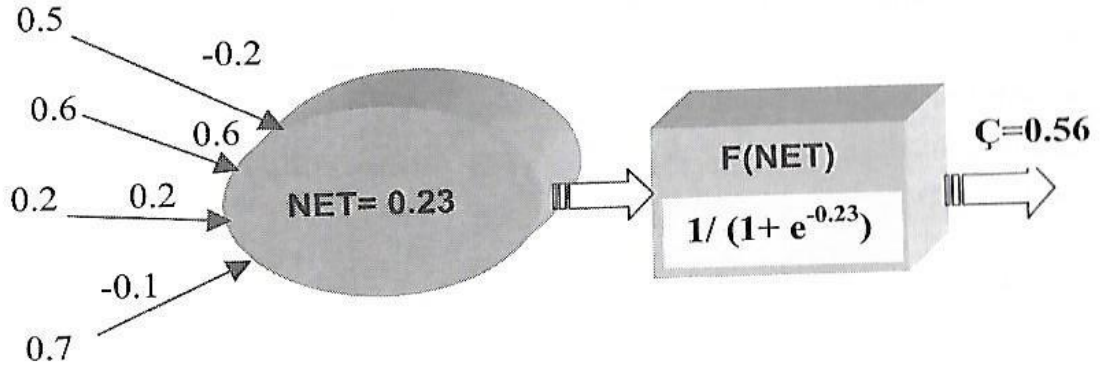
**Çıktı:** Aktivasyon fonksiyonuna giren NET girdinin sonucudur (Şekil 3.5). Çıktı dış dünyaya verilebileceği gibi başka bir işlem(proses) elemanına girdi değeri olarak sunulabilir. Bir yapay sinir hücresinin bir çıktı üretebilir ancak bu çıktı birçok işlem(proses) elemanına girdi olarak sunulabilir.

### 3.1.5. Yapay sinir hücresinin çalışma prensibi ve yapısı

Bir yapay sinir hücresinin çalışma prensibi için veri girişinden çıktı bölümüne kadar olan işlem sırasını ele almak gerekir. Hücreye gelen bilgi veya bilgiler (bu bilgiler dışarıdan gelebileceği gibi başka proses elemanlarından da gelebilir.) toplama fonksiyonuna girer öncelikle burada seçilen toplama fonksiyonu ile işlendikten sonra toplam fonksiyonundan çıkan sonuç aktivasyon fonksiyonuna girer. Seçilen aktivasyon fonksiyonuna göre giren NET değeri aktivasyon fonksiyonunda işlenerek çıktı olarak dışarıya veya başka işlem(proses) elemanlarına girdi veri olarak iletilir. Daha açık bir

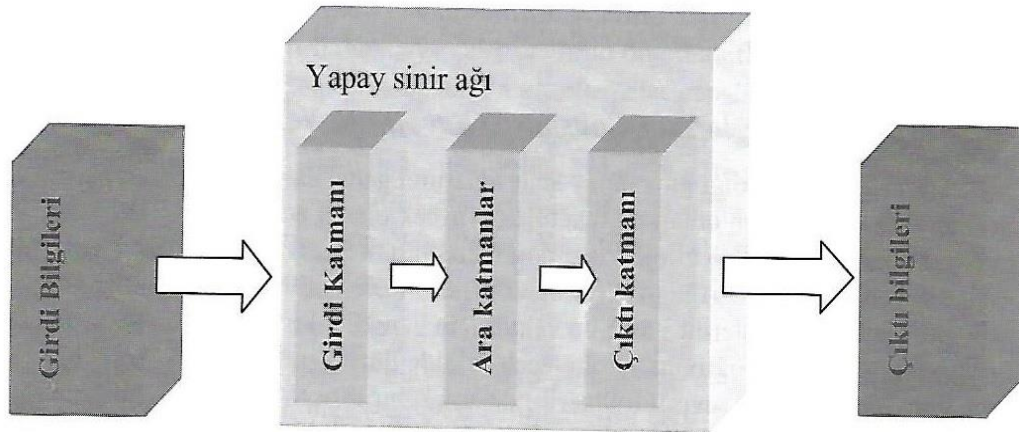


ifadeyle toplama fonksiyonunun ağırlıklı toplam, aktivasyon fonksiyonunun sigmoid fonksiyon seçildiği varsayılırsa çalışma prensibi Şekil 3.6'da gösterilmektedir.



Şekil 3.6. Yapay sinir hücresinin çalışma örneği (Öztemel, 2016).

Bir yapay sinir ağı, birden çok işlem(proses) elemanının bir araya gelerek belirli bir organizasyonda, belli kurallar ve ilişkiler içinde oluşturduğu yapıdır. Bir ağ da görev yapan proses elemanları belli görevlerde özelleşerek belirli kümeler altında toplanırlar. Bu kümelere katmanlar denmektedir. İlk yapay sinir ağları sadece girdi ve çıktı katmanlarından oluşurken daha sonradan bu katmanlara ara katmanda eklenmiştir (Şekil 3.7).

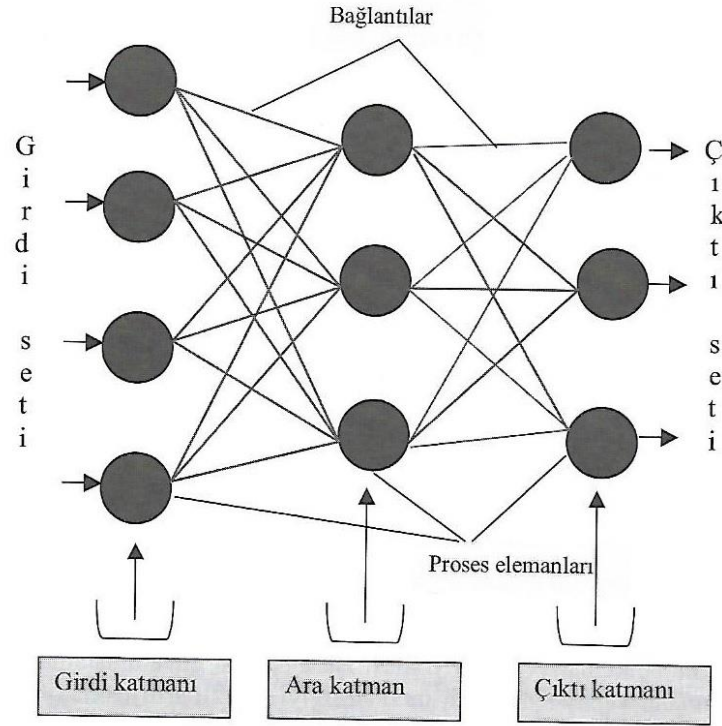


Şekil 3.7. Yapay sinir ağı katmanların birbiriyle ilişkisi (Öztemel, 2016).

**Girdi katmanı:** örneklerden gelen girdi verilerinin ilk olarak ağa girdiği katmandır. Bu katman verileri ara katmana iletmekle yükümlüdür.

**Ara katman:** Girdi katmanından gelen veriler işleyerek çıktı katmanına göndermekle sorumludur. Bir ağda birden fazla ara katman olabilir.

**Çıktı katmanı:** Ara katmandan gelen verileri işleyerek sonuç ürün olan çıktıyı verir.



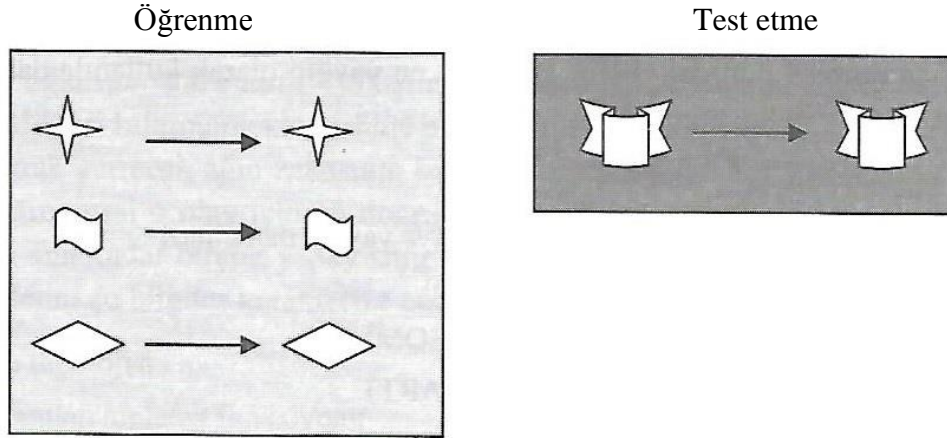
**Şekil 3.8.** Bir yapay sinir örneği (Öztemel, 2016).

Proses elemanları aralılarındaki bağlantılar aracılığı ile ilişkilendirilir (Şekil 3.8). Proses elemanlarının aralarındaki bağlantılarda ağırlıklar mevcuttur ve bu ağırlıklar öğrenme sırasında değişerek öğrenmeyi gerçekleştirir.

### 3.1.6. Yapay sinir ağlarının çalışması ve test edilmesi

Bir yapay sinir ağının görevi ağa gelen girdi setini alarak çıktı üretmektir. Yapay sinir ağları giren bilgi nümerik olmalıdır. Yapay sinir ağlarının çalışmasında öğrenmenin gerçekleşmesindeki amaç işlem(proses) elemanları arasındaki bağlantılardaki ağırlıkların değiştirilmesidir. Yani öğrenme ağırlıklarının değiştirilmesi sonucu oluşan bir sonuçtur. Ancak yapay sinir ağları hangi girdisinin veya ağırlık değeri ağın eğitim durumu hakkında bilgi vermez. Bu durumu yapay sinir ağları açıklayamamaktadır. Yapay sinir ağlarının önemi ve elde ettiği başarı her şeye rağmen güvensizlik oluşturmaktadır.

Bir ağın testi için ise ağa daha önceden hazırlanmış ancak gösterilmemiş veriler gösterilir ve doğru sonuçlar vermesi beklenir.



Şekil 3.9. Öğrenme Test etme (Öztemel, 2016).

### 3.1.7. Yapay sinir ağlarında en fazla kullanılan modeller

Yapay sinir ağlarında işlem(proses) elemanlarının şekilleri kullandıkları toplama ve aktivasyon fonksiyonlarına göre, öğrenme stratejileri ve kullanım alanlarına göre farklı modeller geliştirilmiştir. Aşağıda en yaygın kullanılan modeller sunulmuştur. Bunlar;

- algılayıcılar,
- çok katmanlı algılayıcılar,
- vektör kuantizasyon modelleri,
- kendi kendini organize eden modeller,
- adaptif rezonans teorisi modelleri,
- elman ağları,

şeklinde sıralanabilir.

Bahsedilen ağlardan çok katmanlı algılayıcılar çok iyi bir tahmin edici olması dolayısı ile bu model ayrıntılı olarak incelenecektir. Çok katmanlı algılayıcılar haritacılık faaliyetlerde en çok tercih edilen modellerden biri olarak görülebilir. Kestirim özelliği sebebi ile jeoit problemlerine bu modeller ile çözüm aranacaktır.

Çok katmanlı algılayıcılar yapay zekâ teknolojilerinde ve yapay sinir ağlarında çok önemli bir dönüm noktası teşkil etmektedir. Yapay sinir ağları çok katmanlı algılayıcılar modelinden önce bir durağanlık dönemine girmiştir. Çünkü yapay sinir ağları doğrusal problemlere çözüm üretebilirken doğrusal olmayan problemler karşısında bir çözüm üretememektedir. Devam eden bölümlerde de bahsedilecek olan

XOR probleminin çözümü ile birlikte yapay sinir ağlarının önemi artmıştır. Doğrusal olmayan problemlere yapay sinir ağlarıyla çözümler aranmaya başlanmıştır.

### 3.1.8. XOR problemi

XOR problemi ile ilgili bir bilgi vermek aynı zamanda doğrusal olmayan problemleri ve çok katmanlı algılayıcıları anlamak için önemli bir örnek olacaktır. Bu problemde girdi değerlerinin birbirinin aynısı olması durumunda ağ sıfır sonucunu üretirken girdi değerlerinin farklı olması durumunda ağ bir sonucunu üretmektedir.


Çizelge 3.3. XOR problemi

Girdi 1	Girdi 2	Çıktı
0	0	0
0	1	1
1	0	1
1	1	0

Çizelge 3.3 de gösterildiği gibi iki girdi değeri ağa tanıtılarak çıktı değerlerini üretmesi isteniyor. Yani ağın bu durumu öğrenmesi isteniyor. Yapay sinir ağlarında ilk çok katmanlı algılayıcılar ile doğrusal olmayan bu problemlere çözüm sağlayabilmiştir.

### 3.1.9. Çok katmanlı algılayıcıların yapısı

Çok katmanlı algılayıcıların yapısı Şekil 3.10'da gösterildiği gibidir. G1, G2, ... GN gibi girdi değerleri girdi katmanlarına girer. Girdi katmanında her bir proses elemanının bir girdi ve bir çıktı değeri vardır. Girdi katmanına giren veri herhangi bir işlem uygulanmaksızın ara katman iletilmek üzere çıkar. Bu katmanda herhangi bir işlem yapılmaz.



Şekil 3.10. Çok katmanlı algılayıcıların yapısı (Öztemel, 2016).

Girdi katmanlarından gelen veriler bağlantılar üzerindeki ağırlık değerleri ile belirlenen hesaplama algoritması ile işlem görür. Belirlenen toplama fonksiyonu ile proses elemanına girer proses elemanın içinde yine belirlenen  $F(\text{net})$  fonksiyonundan işlem görerek bir sonraki katmandaki proses elemanlarında işlem görmek üzere çıkar. Ara katman yapısı tek veya birden çok katmandan oluşabilir. Bu katmanlardaki proses elemanlarının sayısı ve katman sayıları tamamen tasarımcının öngörüsüne bağlıdır. Bu topolojiyi belirlemek için bir kural yoktur. Genel olarak deneme-yanılma yolu ile ara katman sayısı ve bu katmanlardaki proses elemanı sayısı belirlenmektedir.

Ara katmanlarda işlenen veriler çıktı verisini üretmek üzere çıktı katmanına girer bu katman da veriler ara katmandaki prosedüre uygun olarak işlenerek dış dünyaya çıktı olarak verilmek üzere işlenir. Çıktı değerleri üretilir.

Eşik değer proses elemanları ise net verinin 0 (sıfır) olması durumuna karşı sonucunda sıfır çıkmasını önlemek amacı ile konmuştur. Tüm ara katmanlara ve çıktı katmanına değer gönderir. Proses eleman değeri daima 1 (bir) dir. Ancak ağırlık değeri değişir.

### 3.1.10. Çok katmanlı algılayıcıların öğrenme kuralı

Çok katmanlı algılayıcılar öğretmenli öğrenme stratejisine göre çalışırlar. Yani ağlara eğitim sırasında hem girdiler hem de o girdilere karşılık üretilmesi gereken (beklenen) çıktılar gösterilir. Ağın görevi her girdi için o girdiye karşılık gelen çıktıyı

üretmektir. Çok katmanlı algılayıcı ağının öğrenme kuralı en küçük kareler yöntemine dayalı Delta öğrenme kuralının genelleştirilmiş halidir. O nedenle öğrenme kuralı genelleştirilmiş Delta kuralı da denmektedir (Öztemel, 2016).

Genelleştirilmiş Delta kuralı iki safhadan oluşmaktadır.

1. İleri doğru hesaplama
2. Geriye doğru hesaplama

### İleriye Doğru Hesaplama

Yapay sinir ağlarının öğrenmesini öğrenme algoritmalarını ele almak gerekirse öncelikle örneklerdeki girdi verileri, girdi katmanına girer bu değerler girdi değerleri herhangi bir işleme tabi tutulmadan çıkar:

$$\zeta_k^i = G_k \quad (3.3)$$

Girdi katmanından çıkan veri ara katmanlara gönderilir. Girdi katmanı ile ara katman arasında bağlantılarda rasgele atanmış olan ağırlık değerleri bulunur. Bu ağırlık değerleri ile belirlenen toplama fonksiyonuna göre toplama işlemi gerçekleştirilir. Ara katman proses elemanın her biri için NET değerinin hesaplanması gerekir. NET işlem(proses) elemanına giriş değeri aktivasyon fonksiyonunda yerine konularak proses elemanına ait çıktı değeri hesaplanır. NET değer ağırlıklı toplama, aktivasyon fonksiyonu ise sigmoid fonksiyon olması halinde,

$$NET_j^a = \sum_{k=1}^n A_{kj} \zeta_k^i \quad (3.4)$$

proses elemanına giriş değeri üreten fonksiyon olur. Burada  $A_{kj}$  ağırlık değerleri  $\zeta_k^i$  ise,

$$\zeta_j^a = \frac{1}{1 + e^{-(NET_j^a + B_j^a)}} \quad (3.5)$$

proses elemanlarından çıktı değerleridir. Bu bağıntılardaki  $B_j^a$  ara karmandaki j proses elemanına bağlanan eşik değerin ağırlığını göstermektedir. Eşik değeri proses elemanın çıktı değeri sabit olup daima 1 dir. Bu eleman aktivasyon fonksiyonunun oryantasyonunu sağlamak için kullanılmaktadır. Girdi değerlerinin tamamının sıfır olması durumunda sonucun devamlı sıfır çıkmasını önlemek amacıyla kullanılır.

Ara katmanda yapılan işlemlerin tamamı diğer ara katman elemanları için ve çıktı katmanı için de yapılarak ağın çıktı üretmesi sağlanır. Burada bahsedilen hesaplamaların tümüne ileriye doğru hesaplama denmektedir.

## Geriyeye Doğru Hesaplama

İleri olarak hesaplanan çıktı değeri ile örneğin sonucu arasındaki fark ağırlık o ağırlıktaki değeri için hatasını ifade etmektedir. Daha önceden de ifade edildiği gibi ağırlık öğrenmesi proses elemanları arasındaki bağlantılardaki ağırlık değerleri sayesinde gerçekleşmektedir. Geriyeye doğru hesaplamada da tam olarak uygun ağırlık değerleri aranmaktadır. Geriyeye doğru hesaplamada proses elemanları arasındaki ağırlık değerleri değiştirilmektedir.

Geriyeye hesaplamada öncelikle beklenen çıktı ile ağırlık çıktısı arasındaki farka bakılarak hata değeri bulunur. Bulunan hata değeri ağırlıklara dağıtılır. Hata ifadesi,

$$E_m = B_m - \zeta_m \quad (3.6)$$

eşitliği ile hesaplanır. Eğer sonuç çıktı birden fazla ise yani ağırlık birden fazla çıktı üretmesini istediyseniz bu durumda toplam hatayı,

$$TH = \sqrt{\sum_m E_m^2} \quad (3.7)$$

eşitliği ile hesaplanır. Hata değerleri görüldükten sonra yeni örneği göstermeden önce hatanın dağıtılması gerekmektedir. Bu işlemde iki durum söz konusudur:

- Ara katmanla çıktı katmanı arasındaki ağırlıkların değiştirilmesi,
- Ara katmanlar arası veya girdi katmanı ile ara katman arasındaki ağırlıkların değiştirilmesidir

Ara katman ile çıktı katmanı arasındaki ağırlıkların değiştirilmesinde ağırlıkların değişim miktarı,

$$\Delta A_{jm}^a(t) = \lambda \delta_m \zeta_j^a + \alpha \Delta A_{jm}^a(t-1) \quad (3.8)$$

eşitliğiyle hesaplanır. Bu bağıntıda  $\lambda$  öğrenme katsayısı,  $\alpha$  momentum katsayısıdır. Bu değerler başlangıçta tasarımcı tarafından verilen değerlerdir. Bu bağıntıda tek bilinmeyen değer  $\delta_m$  hata terimidir. Bunu hesaplanması,

$$\delta_m = f'(NET) \cdot E_m \quad (3.9)$$

şeklinde hesaplanır. Aktivasyon fonksiyonunun yerine sigmoid kullanılması durumunda,

$$\delta_m = \zeta_m(1 - \zeta_m) \cdot E_m \quad (3.10)$$

eşitliği ortaya çıkar.

Yeni ağırlık değerleri ise,

$$A_{jm}^a(t) = A_{jm}^a(t-1) + \Delta A_{jm}^a(t) \quad (3.11)$$

olarak hesaplanır.

Eşik değer ünitesi de ağırlıkların değişim miktarı ise eşitlik (3.11) benzer şekilde değişmektedir. Eşik değer ünitesinin çıktı değeri daima 1 olmasından dolayı formül yeniden düzenlenirse,

$$\Delta \beta_m^c(t) = \lambda \delta_m + \alpha \Delta \beta_m^c(t-1) \quad (3.12)$$

değişim miktarı hesaplanır.

Yeni ağırlık değerleri ise,

$$\beta_m^c(t) = \beta_m^c(t-1) + \Delta \beta_m^c(t) \quad (3.13)$$

olarak belirlenir.

Ara katmanlar arası veya girdi katmanı ile ara katman arası ağırlıkların değiştirilmesinde ise ileriye doğru hesaplamaya benzer bir şekilde hesaplanmaktadır.

Proses elemanları arasındaki ağırlıkların değişimi,

$$\Delta A_{kj}^i(t) = \lambda \delta_j^a \zeta_k^i + \alpha \Delta A_{kj}^i(t-1) \quad (3.14)$$

benzer şekilde belirlenir. Buradaki bilinmeyen tek değer olan hata terimi hesabı,

$$\delta_j^a = f'(NET) \sum_m \delta_m A_{jm}^a \quad (3.15)$$

ve burada da aktivasyon fonksiyonu olarak sigmoid fonksiyonu kullanılması durumunda,

$$\delta_j^a = \zeta_j^a(1 - \zeta_j^a) \sum_m \delta_m A_{jm}^a \quad (3.16)$$

sonucuna ulaşılır. Yeni ağırlık değerleri ise,

$$A_{kj}^i(t) = A_{kj}^i(t-1) + \Delta A_{kj}^i(t) \quad (3.17)$$



şeklinde olacaktır.

Eşik değer ünitesi de ağırlıkların değişim miktarı da ise eşitlik (3.17) benzer şekilde değişmektedir. Eşik değer ünitesinin çıktı değeri daima 1 olmasından dolayı formül yeniden düzenlenirse,

$$\Delta\beta_j^a(t) = \lambda\delta_j^a + \alpha\Delta\beta_j^a(t-1) \quad (3.18)$$

ve buradan yeni ağırlık değerleri ise

$$\beta_j^a(t) = \beta_j^a(t-1) + \Delta\beta_j^a(t) \quad (3.19)$$

olacaktır.

Belirtilen algoritmalar ile iterasyonlar yapılır ve her seferde ağırlıklar değiştirilerek ağıın öğrenmesi sağlanır. Ağ tüm örnekleri belirtilen hata toleranslarında öğrenene kadar işlem devam ettirilir.

Çok katmanlı algılayıcıların tasarımında dikkat edilmesi gereken hususlar;

- problemin net anlaşılması,
- örneklerin problemi temsil edebilecek şekilde seçilmesi,
- girdilerin gösterim şekli,
- parametre seçimi ve ilk değerlerin atanması,
- ağın topolojisi,
- örneklerin ağa sunulma şekli,
- öğrenme ve durdurma kriterleri,

olarak ifade edilir.

### 3.1.11. Çok katmanlı algılayıcıların test edilmesi ve performansı

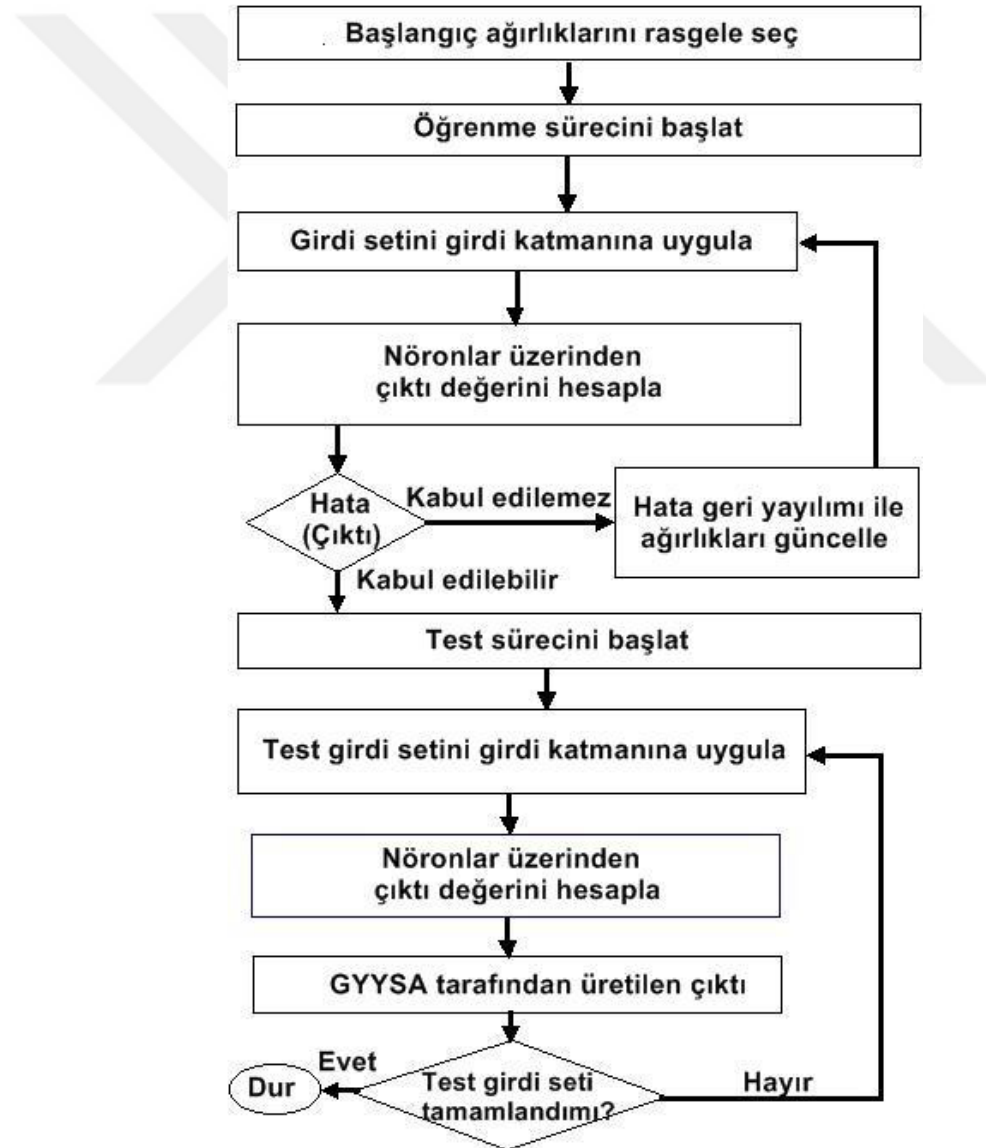
Çok katmanlı algılayıcılarda ağın öğrenip öğrenmediğini veya ne kadar başarılı sonuçlar verdiğini bulabilmemiz için ağın test edilmesi gerekir. Ağın başarı göstergesi ağın daha önceden görmediği örneklere verdiği doğru cevaplarla ölçülür. Bunun için çok katmanlı algılayıcılarda toplam örnekler eğitim seti ve test seti olarak ayrılmalıdır. Eğitim için kullanılacak örnek sayısı ve test için kullanılacak örnek sayıları tamamen tasarımcıya kalmıştır. Bunun için bir yöntem yok deneme-yanılma yolu ile uygun değer örnek sayıları bulunur. Test seti ağdan geçirildikten sonra ağın performansı,

$$P = \frac{D}{T} \times 100 \quad (3.20)$$

eşitliğine göre hesaplanır. Bu bağıntıda  $P$  ağıın performansı,  $D$  test setindeki doğru cevaplanan örnek sayısı  $T$  ise test setindeki toplam örnek sayısıdır.

Eğer tasarlanan ağda performans değerleri performans değeri istenilen gibi çıkmıyorsa ağ bir miktar daha eğitilerek denenir ancak performans yükselmiyorsa ağıın topolojisinin iyi tasarlanamadığı düşünülebilir.

Farklı bir durum olarak ağ eğitim setindeki tüm örnekleri öğrenebilir ancak performans değeri çok düşük kalması durumunda ağıın öğrenmediği ezberlediği kabul edilir. Bu ağı yeniden tasarlayarak kurgunun değiştirilmesi gerekir.



Şekil 3.11 Geri yayılım algoritması için akış diyagramı (Yılmaz, 2012)

### 3.2. Polinomlarla Eğri Yüzey Uydurma

Yükseklik belirlemede ağırlıklı olarak nivelman ölçüleri kullanılmaktadır. Ancak günümüz teknolojisinde nivelman ölçümü yapmak zaman alıcı ve zahmetli bir iş olmaktadır. Gerek zaman gerek iş gücü bakımından emek ve maliyet anlamına gelmektedir. Gelişen teknolojinin en büyük kazanımlarından olan GNSS teknolojisi sayesinde yatay ve düşey konum bilgilerini yüksek hassasiyette belirlemek olanaklıdır. Ancak GNSS'in çalışma prensibi gereği hesap yüzeyi olarak matematiksel bir yüzey kullanılmaktadır. Bu matematiksel yüzey ise dönel elipsoittir. GNSS'den elde edilen yükseklikler elipsoidal yüksekliktir. Elde edilen elipsoidal yükseklik yalnızca geometrik anlam taşımaktadır. Ancak mühendislik uygulamalarından fiziksel anlamlı yükseklik sistemleri kullanılmaktadır. Bunun nedeni akışkanların hareket yönünün doğrudan gravite alanı ile ilişkili olmasıdır. Başka bir deyişle altyapı ve mühendislik hizmetlerinin doğru bir şekilde gerçekleşebilmesi için gravite alanı ile ilişkili yükseklik sistemleri kullanılmalıdır (Üstün, 2002). Dolayısı ile mühendislik problemlerinde elipsoidal yüksekliği her uygulamada doğrudan kullanmamız mümkün görülmemektedir. Üretilen geometrik anlamlı yüksekliğin gravite alanı ile ilişkilendirilmesi halinde fiziksel anlam kazanacaktır. Bu dönüşümü (1.1) eşitliğiyle geçilebilmektedir. Bu durumda jeoit yüksekliğinin yüksek hassasiyette belirlenmesi yapılan işin doğruluğunu belirlemede büyük önem arz etmektedir

Bir bölge için benzer şekilde GNSS - nivelman gözlemleri yardımıyla dayanak noktalarında (hem elipsoidal hem de ortometrik yüksekliği bilinen noktalar) jeoit yükseklikleri hesaplanabilir. Çalışma bölgesinde dayanak noktaları yardımıyla bir yüzey geçirilirse bölge içinde yer alan diğer noktaların jeoit yükseklikleri belirli bir doğrulukta tahmin edilebilir (Abbak, 2017).

#### 3.2.1. Polinomlarla eğri yüzey modelinin oluşturulması

Polinomlarla yüzey uydurma, yerel jeoit belirlemede en çok kullanılan yöntemlerin başında gelmektedir. BÖHBBÜY'ün 42. maddesine göre yerel jeoit oluşturma bu yönteme göre gerçekleştirilmesi gerekmektedir. Bu yöntemde jeoit yüzey bir fonksiyon ile modellenmeye çalışılmaktadır. Koordinatları bilinen dayanak noktalarının oluşturduğu jeoit yüzeyi sırasıyla  $n$ . dereceden ortogonal olmayan polinomlar kullanılarak,

$$N(x, y) = \sum_{i=0}^n \sum_{j=0}^n a_{ij} x^i y^j \quad (3.21)$$

ifade edilebilir (İnal vd., 2003; Abbak, 2017).

Ortogonal polinomlarla jeoit yüzeyi belirlemede kullanılan matematiksel ifade,

$$N(x, y) = \sum_{i=0}^n \sum_{\substack{j=i-k \\ k=0}}^n a_{ij} x^i y^j \quad (3.22)$$

şeklindedir.

Yukarıdaki (3.22) formülün anlaşılır olması bakımından ikinci derece için açarsak,

$$N(x, y) = \sum a_{ij} x^i y^j = a_{00} + a_{10}x + a_{01}y + a_{20}x^2 + a_{11}xy + a_{02}y^2 \quad (3.23)$$

eşitliği ortaya çıkar.

Uygulamada kaçınıcı dereceden polinom kullanılmalıdır sorusu akla gelir. Bu amaçla, dayanak nokta sayısı göz önünde bulundurularak 1., 2. ve 3. derece polinomlar denenir. Genellikle üçüncü dereceyi geçmeyen yüzey polinomu bu işlem için yeterli görülmektedir. Bunlardan karesel ortalama hatası küçük olan çözüm uygun çözüm olarak kabul edilebilir (Abbak, 2017).

**Çizelge 3.4.** 1., 2., 3. Derece polinom elemanları

Derece	i	j	$N(x, y) = \sum a_{ij} x^i y^j$	N
0	0	0	$N(x, y) = \sum a_{00} x^0 y^0$	$N = a_{00}$
1	1	0	$N(x, y) = \sum a_{10} x^1 y^0$	$N = a_{10} \cdot x$
	0	1	$N(x, y) = \sum a_{01} x^0 y^1$	$N = a_{01} \cdot y$
2	2	0	$N(x, y) = \sum a_{20} x^2 y^0$	$N = a_{20} \cdot x^2$
	1	1	$N(x, y) = \sum a_{11} x^1 y^1$	$N = a_{11} \cdot x \cdot y$
	0	2	$N(x, y) = \sum a_{02} x^0 y^2$	$N = a_{02} \cdot y^2$
3	3	0	$N(x, y) = \sum a_{30} x^3 y^0$	$N = a_{30} \cdot x^3$
	2	1	$N(x, y) = \sum a_{21} x^2 y^1$	$N = a_{21} \cdot x^2 \cdot y$
	1	2	$N(x, y) = \sum a_{12} x^1 y^2$	$N = a_{12} \cdot x \cdot y^2$
	0	3	$N(x, y) = \sum a_{03} x^0 y^3$	$N = a_{03} \cdot y^3$

Ölçüler, bilinmeyenlerin bir fonksiyonu,

$$\mathbf{Ax} = \mathbf{l} \quad (3.24)$$

şeklinde gösterilir. Eşitlikteki  $\mathbf{A}$  katsayılar matrisi,  $\mathbf{x}$  bilinmeyenler vektörü,  $\mathbf{l}$  ölçüler vektörüdür. Böylece bilinmeyen parametrelerini kestirmek için en küçük kareler yaklaşımı uygulanırsa bilinmeyenler vektörü,

$$\mathbf{x} = (\mathbf{A}^T \mathbf{A})^{-1} (\mathbf{A}^T \mathbf{l}) \quad (3.25)$$

elde edilir. Bilinmeyen parametreler tespiti ile birlikte düzeltme denklemlerine bilinmeyen parametreler konarak,

$$\mathbf{v} = \mathbf{Ax} - \mathbf{l} \quad (3.26)$$

ölçülerin düzeltme değerleri hesaplanır. Düzeltme değerlerinden hesaplanan birim ağırlıklı ölçünün karesel ortalama hatası,

$$m_0 = \pm \sqrt{\frac{\mathbf{v}^T \mathbf{v}}{n-u}} \quad (3.27)$$

şeklinde hesaplanır. Buradaki  $n$  değeri ölçü sayısı (dayanak nokta sayısı)  $u$  ise bilinmeyen sayısı (modeldeki bilinmeyen parametre sayısı)'dir. Bu formülden de anlaşılacağı üzere ölçü sayısı bilinmeyen sayısından büyük olması durumda dengeleme hesabı mümkün olacaktır.

### 3.2.2. Polinomlarla eğri yüzey modelinin test edilmesi

BÖHHBÜY'e göre dengeleme sonrası karesel ortalama hatanın  $\pm 5$  cm'nin üstünde çıkması halinde çözüm aranmaz; bunun yerine uyumsuz ölçüler testi uygulanarak hatalı ölçü araştırması yapılır. Eğer varsa bu değer atılarak tekrar dengeleme yapılır. Ortalama hata  $\pm 5$  cm'nin altındaysa  $t$  (student) dağılımına göre parametrelere anlamlılık testi uygulanır. Yönetmeliğe göre istatistiki güven seviyesi  $1 - \alpha = 0.95$  alınmalıdır.

Parametre testi için bilinmeyenlerin ortalama hatalarının hesaplanması için bilinmeyenlerin kovaryans matrisi,

$$\mathbf{Q}_{XX} = \mathbf{N}^{-1} = (\mathbf{A}^T \mathbf{A})^{-1} \quad (3.28)$$

şeklinde hesaplanır. Bilinmeyenlerin karesel ortalama hatası,

$$m_{a_{ij}} = \pm m_0 \sqrt{q_{xx}} \quad (3.29)$$

ve bilinmeyenin  $t$  test değeri,

$$t_{test} = \frac{|a_{ij}|}{m_{a_{ij}}} \quad (3.30)$$

eşitliğiyle belirlenir. Bu değerlerden hesaplanan  $t_{test} > t_{tablo}$  olması durumunda parametre değeri anlamlı olduğu kanısına varılır.  $t_{tablo}$  değerinden düşük çıkması durumunda en düşük değere sahip parametre çıkarılarak çözüm tekrarlanır. Bu döngü tüm parametreler anlamlı olana kadar tekrarlanır. Anlamlı parametrelerle yüzey modeli oluşturulur.

En küçük kareler yöntemine göre çözüm sağlanarak model oluşturulur. Test noktaları üretilen fonksiyonda hesaplanarak üretilen sonuçla olması gereken gerçek değer arasındaki farka bakılarak test noktaları için karesel ortalama hata hesaplanır. Modelin test verileri için ürettiği sonuç modelin başarısını (doğruluğunu) gösterir.

### 3.2.3. Polinomlarla eğri yüzey model ve dikkat edilmesi gerekenler

Bu yöntemin uygulamadaki en zayıf yönü jeoidin hızlı değiştiği yerlerde (dağlık alanlar gibi eğim ve yükseklik farkının hızlı değiştiği bölgelerde) doğruluğu düşük bir işlem olmasıdır. Ancak matematiksel hesaplamaları basit ve hızlı bir yöntemdir.

Uygulamada noktaların yatay konumları 6 ve 7 basamaklı büyük sayılar kullanıldığı durumlarda en küçük kareler çözümünde katsayılar matrisinin elemanları çok büyük ve çok küçük sayılardan oluşmakta ve normal denklem matrisinin kondisyonunu bozmaktadır. Bu durumda yatay koordinat değerlerini ötelemek ve ölçeklendirmek üzere,

$$x'_i = \frac{x_i - x_0}{1000} \quad y'_i = \frac{y_i - y_0}{1000} \quad (3.31)$$

eşitlikleri kullanılmalıdır. Eşitlikteki  $x_0$  ve  $y_0$  koordinatların ortalama değerlerini ifade etmektedir.

Polinomal eğri yüzey uydurma yönteminde jeoidin başarılı bir şekilde temsil edilebilmesi için model oluşturmakta kullanılan dayanak verilerinin seçiminde aşağıdaki hususlara dikkat edilmesi gerekir. Bunlar,

- verilerin çalışma sahasına homojen olarak dağılmış olması,

- verilerin arazinin eğiminin deęiřtięi yerlerde seilmesi,
  - verilerin dere ve zirve gibi yüksek ve düşük yükseklik deęerine sahip noktaların seilmesi,
  - verilerin proje sahasını epeevre sarmasına,
  - temsil nokta sayısının olabildięince fazla seilmesine,
- řeklinde zetlenebilir (Abbak, 2017).




## 4. SAYISAL UYGULAMA

Bu bölümde öncelikle çalışma sahası ve kullanılan veriler tartışılmakta, sonrasında gerçekleştirilen araştırma ayrıntılı olarak verilmektedir.

### 4.1. Çalışma Alanı

Belçika'nın kuzey doğusunda yaklaşık olarak  $50.2^{\circ} < \varphi < 50.7^{\circ}$  kuzey ve  $5.4^{\circ} < \lambda < 6.1^{\circ}$  doğu coğrafi sınırlar arasında kalan engebeli bölge çalışma alanı olarak seçilmiştir. Bölge yaklaşık 50 km x 56 km boyutlarında olup yüzölçümü  $\sim 2765 \text{ km}^2$  dir. Çalışma alanında yükseklik değerleri 150 m ile 550 m arasında değişmektedir. Söz konusu bölge, jeoit ve topografya değişiminin fazla olması nedeniyle çalışma alanı olarak seçilmiştir. Araştırma konusu farklı yoğunluktaki verilerin jeoit modeline etkisi olduğundan sık ve yüksek doğruluklu veriler ancak bu bölgeden temin edilebilmiştir. (Şekil 4.1).



Şekil 4.1. Çalışma bölgesi ve uygulama noktaları



## 4.2. Veriler

Çalışma bölgesine ait GNSS-nivelman verileri Belçika Ulusal Coğrafya Enstitüsünden elde edilmiştir. Çalışma bölgesinde 326 adet GNSS-nivelman noktası bulunmaktadır. Veriler; noktaların UTM (Universal Transversal Merkator) projeksiyon koordinatları ( $x$  ve  $y$ ), elipsoidal yükseklik ( $h$ ) ve ortometrik yükseklik ( $H$ ) değerlerinden oluşmaktadır. Elipsoidal ve ortometrik yüksekliklerin doğruluğu 1'er cm olduğundan noktaların jeoit yüksekliğinin doğruluğu 1—2 cm seviyesindedir (Verbeugt, 2018). Verilere göre çalışma alanında jeoit yüksekliği değişimi 1,764 m olarak hesaplanmıştır. Veriler, çalışmada eğitim ve test verileri olarak ayrıştırılarak jeoit modeli belirlenecektir.

## 4.3. Araştırma

Bu çalışmanın amacı alternatif bir yöntem olarak görülen ileri beslemeli hata geri yayımlı yapay sinir ağlarının jeoit yüksekliğini tahminindeki performansını araştırmaktır. Bu amaçla kıyas yöntemi olarak Büyük Ölçekli Harita ve Harita Bilgileri Üretim Yönetmeliğince (BÖHHBÜY) kabul gören polinomlarla eğri yüzey uydurma seçilmiştir. Polinomal yöntem ile yapay sinir ağları kıyaslanarak yöntemlerin doğruluğu belirlenecektir. Ayrıca veriler çeşitli kombinasyonlarla yöntemlerin çözüm üretmesi istenecektir. Buradaki amaç olası farklı senaryolarda yöntemlerin ne derecede doğru sonuç vereceğini araştırılacak yöntemler karşılaştırılarak sonuçlar irdelenecektir. Elde edilen sonuçlar gereği yapay sinir ağlarının sivil kullanımına yönelik olası karşılaşılabilecek sorunlar ve çözüm önerileri sunulmaya çalışılacaktır.

İlk deneyde tüm verilerin yaklaşık %22'si test verisi olacak şekilde 256 adet eğitim ve 70 adet test verisi olarak seçildi (Şekil 4.2a). Eğitim verilerinin çalışma alanının tamamını kapsayacak şekilde homojen dağılmış olmasına dikkat edildi. İkinci deneyde yine homojen dağılmış şekilde 200 adet eğitim 126 adet test verisi seçildi (Şekil 4.2b). Bu dağılımın seçilme nedeni yönetmeliğin 42. maddesi gereğince en az sayıda eğitim verisinde üretilecek sonuçların görülmesi amaçlanmıştır. Üçüncü deneyde yönetmelikte belirtilen sınırların dışına çıkılarak homojen olarak dağılmış 150 adet eğitim noktası 176 adet test noktası seçildi (Şekil 4.2c). Dördüncü deneyde modelleri daha da zorlamak ve başarılarını daha net olarak ayırtırmak amacı ile homojen olarak dağılmış 100 adet eğitim noktası ve 226 adet test noktası seçildi (Şekil 4.2d). Beşinci deneyde yine homojen dağılmış olmak şartıyla birinci deneyde kullanılan test verileri

eđitim, eđitim verileri test verileri olarak kullanılmak suretiyle eđitim veriler tđm verilen yaklaşık %22 olana kadar azaltılarak modeller iyice zorlanmıřtır (řekil 4.2e). Eđitim verilerinin bu denli azaltılmasının amacı eđitim verilerinin modellerin bařarisına olan etkisini gđrmektir. Altıncı deneyde ise verilerin homojen dađılmamıř durumda yđntemlerin ne dođrulukta sonuřlar urediđini gđrmek amařlanmıřtır. alıřma alanının ortasındaki 133 nokta eđitim verisi olarak seřilmiř bu noktaların dıřındaki 193 adet nokta test verisi olarak kullanılmıřtır (řekil 4.2f).

**izelge 4.1.** Deneylerdeki eđitim ve test verilerinin sayısı

Deney no	Eđitim veri sayısı	Test veri sayısı	Nokta dađılımı
1	256	70	Homojen
2	200	126	Homojen
3	150	176	Homojen
4	100	226	Homojen
5	70	256	Homojen
6	133	193	Homojen deđil

Yapay sinir ađ modelini ve polinomal eđri yzzey modelini oluřturmak iin MATLAB 2016 programlama dili kullanılmıřtır. Polinomal eđri yzzey modelini oluřturmak iin MATLAB'ın program geliřtirme ortamında hazır bir fonksiyon kullanılmaksızın bir yazılım geliřtirilmiřtir. Diđer yandan ileri beslemeli hata geri yayımlı yapay sinir ađı iin MATLAB'ın yapay sinir ađları modlnde (Neural Network Toolbox) hazır fonksiyonlar (network) kullanılarak programlanmıřtır.

Polinomal eđri yzzey oluřtururken öncelikle alıřma alanın en iyi uyan polinomun derecesi arařtırıldı. 1. ve 2. derece özümde öncül KOH 5 cm üstünde kaldıđı görüldü (1. derece 8.88 cm ve 2. derece 5.88 cm). 3. derece özüm ise 3.21 cm iken optimum özümün 4. dereceden polinom olduđu görüldü (2.25 cm). Parametre testi ile anlamsız parametreler atılarak jeoit modeli oluřturuldu.

Yapay sinir ađlarında model oluřurmada belirli bir kural yoktur. Ara katman sayıları, ara katmanlardaki proses elemanı sayısı, öđrenme algoritması, toplama fonksiyonu, iterasyon sayısı gibi deđiřkenler deneme-yanılma yoluyla belirlenebilmektedir. Bu nedenle verilerin özümünde ok sayıda deneme yapılarak hata deđerisi en aza indirgenir. Bu denemelerde en az 1 en ok 10 adet ara katman sayısı belirlenmiřtir. Ara katmanlardaki nöron sayısı olarak en az 10 en ok 700 olarak denemeler yapılmıřtır. Bu amala ađın en iyi öđrenme modeli olarak 2 ara katmanda ve ara katman proses elemanı sayıları 20 ve 30 olarak bulunmuřtur.


Eđitim setleri programlara girdi olarak verilerek öncelikle uygun model arařtırması yapılmıř ve optimum çözümdede eđitim verileri için karesel ortalama hatası hesaplanmıřtır. Aynı modellere test verileri de sunularak bu noktalar için sonuç üretmesi istenmiřtir. Üretilen ile gerçek sonuçlar irdelenerek en iyi ve en kötü tahmin deđerleri ile test setinin karesel ortalama hatası hesaplanmıřtır (Çizelge 4.2).

**Çizelge 4.2.** Yapay sinir ađları ve polinomal modellerin karşılařtırması (cm)

Deney No	Eđitim seti adedi	Test seti adedi	Yapay sinir ađları				Polinomal eđri uydurma			
			KOH Eđitim	KOH Test	Test seti maksimum hata	Test seti minimum hata	KOH Eđitim	KOH Test	Test seti maksimum hata	Test seti minimum hata
1	256	70	0.53	0.92	2.57	0.02	2.24	2.07	6.38	0.09
2	200	126	0.68	0.99	3.36	0.01	2.23	2.20	6.47	0.01
3	150	176	0.65	1.00	3.25	0.01	2.11	2.32	5.80	1.25
4	100	226	0.82	1.12	3.40	0.00	2.29	2.26	7.26	0.00
5	70	256	0.90	1.55	5.53	0.01	2.01	2.69	11.86	0.02
6	133	193	0.53	5.99	23.08	0.04	1.52	30.13	169.70	0.02

Homojen dađılmıř veriler kullanılarak yapılan deneyler irdelendiđinde:

- 1) Her iki yöntemden de iyi sonuçlar (yönetmeliđe uygun) elde edildiđi görölmektedir. Bu durumun nedeni kullanılan verilerin yüksek dođrulukta olmasıdır.
- 2) Yapay sinir ađlarından üretilen sonuçlar incelendiđinde eđitimde kullanılan verilerin karesel ortalama hatalarının çok düşük mertebelerde olduđu ancak test verindeki KOH sonuçlarında aynı başarıyı gösteremediđi görölmektedir. Polinomal eđri yüzey uydurmada ise eđitim ve test verilerine ait karesel ortalama hataların birbirlerine çok daha yakın olduđu görölmektedir. Bu yönü ile bakıldıđı zaman yapay sinir ađlarının eđitim verilerinden üretilen karesel ortalama hata deđerinin sonucun dođruluđu hakkında gerçeđi yansıtmadıđı kanısına varılır.
- 3) Yöntemleri test verilerinin karesel ortalama hataları yönünden kıyaslamak modellerin ürettiđi verilerin dođruluđu, dolayısıyla modellerin dođruluđu anlamına gelmektedir. Bu anlamda sonuçlara bakıldıđı zaman sonuçlar birbirine yakın gözükmesine karşın yapay sinir ađlarının, polinomal eđri yüzey uydurma yöntemine kıyasla iki kat daha dođru sonuç ürettiđi görölmüřtür. Sonuçlar yapay sinir ađlarının çok daha güçlü bir model olduđunu göstermektedir. Bu da jeoit yüksekliđinin çok hızlı deđiřtiđi bölgelerde çok daha iyi sonuçlar üretebileceđi anlamına gelmektedir.



Şekil 4.2. Deneylerdeki noktaların coğrafi dağılımı (kırmızı: eğitim, mavi: test verilerini göstermektedir)

- 4) Test verilerindeki maksimum hatalar incelenirse yapay sinir ağı modelinde eğitim verisinin azalmasına paralel olarak hataları yaklaşık 3 cm ile 6 cm arasında değiştiği görülmektedir. Polinomal eğri uydurma yönteminde yine bu değerlerin eğitim verisinin azalmasına paralel olarak yaklaşık 6 cm ile 12 cm arasında değiştiği görülmüştür. Mühendislik uygulamalarında üretilecek verilerde yapay sinir ağları modeli ile üretilen verinin çok daha doğru olduğu görüldüğünden bu tercih nedeni olacaktır.
- 5) Deney-6 homojen olarak dağılmamış verilere ait sonuçlar irdelendiğinde yöntemlerin birbirlerinden net bir şekilde ayrıştığı görülmektedir. Modellerin doğruluklarının görülmesi amacıyla test verilerinin karesel ortalama hataları kıyaslanırsa yapay sinir ağlarının yaklaşık hatasının 6 cm olduğu polinomal yöntemin ise yaklaşık 30 cm olduğu görülmüştür. Test setlerinin maksimum hatalarına bakıldığında ise yapay sinir ağlarının yaklaşık 23 cm olduğu polinomal eğri uydurmanın ise yaklaşık 170 cm olduğu görülmektedir.

Bu konuda yapılmış diğer çalışmalar ile kıyaslandığında çalışma verileri olarak kimi çalışmalarda belirli bir fonksiyon aracılığı veya bir jeoit modeli kullanılarak simülasyon verileri ve çeşitli çalışmalar veya jeodezik ağlardaki veriler ile çalışma yapılmıştır. Bu çalışmada ise yönetmeliğin sınırlarını da kapsayacak şekilde uygun yoğunlukta ve farklı deneyler yapmaya elverecek nitelikte veri kullanılmaya dikkat edilmiştir.

Çalışmada farklı yoğunlukta noktalar kullanılarak yönetmelikte bahsedilen polinomal eğri yüzey uydurma yöntemi ile kıyaslanmıştır. Literatürde birçok çalışmada birçok yöntem birbiri ile kıyas yapılmış ancak homojen olmayan farklı nokta yoğunluğundaki verilerle kıyasına rastlanmamıştır.

Bunlar dışında yapılan tüm çalışmalarda eğitim verilerinin homojen olarak dağıldığı varsayımına dayanarak çalışmalar yürütülmüştür. Eğitim verilerinin homojen olarak dağılmadığı varsayımına dayanan bir çalışmaya rastlanmamıştır. Homojen dağılmayan veriler ışığında yapılacak doğru tahminlerin yöntemin gücünü gösterir nitelikte olduğu düşünülebilir. Yapay sinir ağlarında bu durumun araştırması yapılmıştır. Homojen ve homojen olmayan veri dağılımlarında yapay sinir ağları model doğruluğunu göstermiştir.

## 5. SONUÇLAR VE ÖNERİLER

Bu çalışmada yapay sinir ağları ve polinomal eğri yüzey uydurma teori ve kavramları açıklanmış, yerel jeoit belirleme konusunda çözümler araştırılmıştır. Sayısal uygulamada 2765 km<sup>2</sup> lik bir alan seçilmiş, bu alanda farklı nokta sayıları ile jeoit modellenmiş ve modellerin doğrulukları araştırılmıştır.

Birinci deneyde tüm verilerin %20'si test verisi olarak belirlenmiş, her iki yöntem ile yüksek doğruluklu modeller üretilmiştir. Ancak yöntemler birbirlerine göre kıyaslanırsa yapay sinir ağı yönteminin daha iyi sonuç ürettiği görülmüştür.

İkinci deneyde yönetmelik (BÖHHBÜY) dikkate alınarak eğitim verileri minimumda tutulmuş, yöntemlerin modelleri iyi sonuçlar vermiş ve yönetmeliğin hata sınırları içinde kalmıştır. Bu deneyde de yapay sinir ağı modeli polinomal yöntemle oranla daha iyi sonuç üretmiştir.

Üçüncü, dördüncü ve beşinci deneyde eğitim noktalarının kademeli olarak azaltılması modellerin yüzeyleri tasvir gücünde azalma yaşandığı göstermiştir. Bu azalma eğitim setindeki veri adedi ile doğru orantılı olduğunu kanıtlar niteliktedir. Model doğruluklarındaki azalmanın çok fazla olmadığı görülmüştür. Sonuçların tamamı yönetmelikteki sınır değeri ile kıyaslandığında sınırları içerisinde kaldığı görülmüştür. Ancak sonuçların bu denli istikrarlı kalması ve ani değişimlerin yaşanmamasının temel nedeni eğitimde kullanılan nokta verilerinin yüksek doğruluklu olması ve noktaların homojen olarak dağılmış olmasıdır. Yapılan ilk beş deneyde homojen dağılmış verilerin ürettiği sonuçlardır. Bu deneylerde değiştirilen parametreler, eğitim veri adedi olup eğitim veri adedinin model doğruluğuna etkisi görülmüştür. Yöntemlerin kıyaslamasında ise yapay sinir ağları yine çok iyi sonuçlar vermiştir. Üretilen sonuçların yönetmelik sınır içerisinde kalması sonuçların her iki yöntemde de kabul edilebileceği anlamına gelmesine karşın uygulamalarda gerçeğe en yakın sonuçların kullanılması arzu edilir. Bu durumda sonuçların tekrar bakıldığında doğrulukla oransal olarak yapay sinir ağlarının yaklaşık iki kat daha başarılı olduğu sonucu ortadadır.

Altıncı deneyde ise yöntemlerin belirttiği uygun değer koşulların dışına çıkılarak eğitim nokta verilerinin homojen dağılmaması durumunda yöntemlerin üreteceği sonuçlar araştırılmıştır. Polinomal yöntem ve yapay sinir ağlarında örnekleme noktalarının problemin tamamını tanımlar nitelikte olması gerekmektedir. Buradaki durum ise eğitim verilerinin problemi tam tanımlar düzeyde olmayıp eğitim noktalarının dışındaki alanda daha önceden örneklerini görmediği noktalar için sonuç üretmesi

istenmiştir. Bu deneyde elde edilen sonuçlara göre polinomal yöntemin yüzeyi modelleyemediği ve model yapısının bir anda bozulduğu belirlenmiştir. Diğer yandan yapay sinir ağlarında da model yapısının bozulduğu görülmüştür. Ancak polinomal yönteme oranla daha iyi sonuçlar üretmiş ve çalışma alanı dışındaki (ekstrapolasyon) noktalarda dahi güvenilir bir sonuç elde edilmiştir.

Tüm deneylerin sonuçlarından yola çıkarak yapılan denemeler sonucunda ileri beslemeli geri yayımlı yapay sinir ağlarının jeoit belirlemede polinomal yönteme oranla çok daha iyi sonuçlar ürettiği anlaşılmıştır.

Yapay sinir ağları ile üretilen bu sonuçlar günümüzde popüler bir teknoloji olmasının sebebinin kanıtlar niteliktedir. Bunlara rağmen uygulamada da görüldüğü üzere çoğu parametre deneme-yanılma yöntemi ve kişisel deneyimlerle elde edilmektedir. Bu yöntemi gündelik hayatta kullanmak için kullanıcının yapay sinir ağı konusunda uzman olması gerekmektedir. Bu problemi aşabilmek için günümüz teknolojisi ile deneme-yanılma yöntemlerini kendisi otonom olarak gerçekleştirerek kendi kendine öğrenebilen ve optimum çözümü üretebilecek yazılımlar ile son kullanıcının hizmetine sunulabilir. Ayrıca yapay sinir ağların öğrenmesi sırasında oluşan ağır işlem yükü ve öğrenme sürelerinin uzunluğu sebebi ile sonuçların üretilmesi donanımına bağımlı hale getirmektedir. Hızlı ve anlık çözülmesi gereken problemlerde yapay sinir ağlarının diğer yöntemlere oranla yetersiz kalacağı bir diğer zayıflık olarak değerlendirilmektedir. Ancak sınırlı sayıdaki verilerde dahi ileri beslemeli geri yayımlı yapay sinir ağlarının ne denli doğru sonuç ürettiği görülmektedir. Yapay sinir ağları ile jeoit belirleme konusundaki en büyük problem yapay sinir ağları konusunda uzman olmayan kullanıcının kullanımına açık olmaması, ağır işlem yükü ve zaman problemleri ise nispeten gelişen teknolojide her geçen gün kılalacağı bir problem olmaktan çıkacağı düşünülebilir. Yapay sinir ağlarının belirli bir algoritma ile kesin olarak çözüm getirilemeyen problemler çözebilmesi ile yapay sinir ağlarının bir anda popüler ve başarılı bir teknoloji haline getirmekte en önemli nedenidir. Yapay sinir ağlarının son kullanıcının kullanımına hazır hale getirmek ise bu teknolojiyi çok daha popüler hale getireceği ve geleceğin şekillenmesinde bu teknolojinin büyük etkisi olacağı kaçınılmazdır. Bu problemin çözümünde çeşitli prosedürler belirlenerek yapay sinir ağlarının modelinde bir otomasyon kazandırılabilir ancak ara katman sayısı, katmanlardaki nöron sayıları, öğrenme ve momentum katsayıları, aktivasyon fonksiyonu gibi parametrelerin çok olması bu teknolojinin en büyük zayıflığı olarak

görülmektedir. Belirtilen öneriler ışığında gerekli yazılımlar üretilebilirse jeodezik projelerde yapay sinir ağıları bir seçenek olarak kullanılabilir.





## KAYNAKLAR

- Abbak, R. A., 2017, Fiziksel Jeodezi Teori ve Uygulama, *Atlas Akademi Yayıncılık*, Konya.
- Arslan, O., Kurt, O., Konak, H., 2007, Yapay Sinir Ağlarının Jeodezide Uygulamaları Üzerine Öneriler, *11. Türkiye Harita Bilimsel ve Teknik Kurultayı*, 2-6 Nisan 2007, Ankara.
- Aşık, E., 2013, Lokal Jeoit Belirlemede Yapay Sinir Ağları ve Kriging Yönteminin Karşılaştırılması, Yüksek Lisans Tezi, *Afyon Kocatepe Üniversitesi Fen Bilimleri Enstitüsü*, Afyon.
- 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.
- Beale, M.H., Hagan, M.T. and Demuth, H.B., 2010, Neural Network Toolbox 7 User's Guide. The MathWorks Inc., Natick, MA.
- Çakır, L., 2015, Sayısal Yükseklik Modelinde Klasik Ve Esnek Hesaplama Yöntemlerinin Karşılaştırılması, *15. Türkiye Harita Bilimsel ve Teknik Kurultayı*, 25-28 Mart 2015, Ankara.
- Çorumluoğlu, Ö., Özbay, Y., Kalaycı, İ., Şanlıoğlu, İ., 2005, GPS Yüksekliklerinden Ortometrik yüksekliklerin elde edilmesinde Yapay Sinir Ağı (YSA) Tekniğinin kullanımı, *2. Mühendislik Ölçmeleri sempozyumu*, 23-25 Kasım 2005, İstanbul.
- Franke, R., 1979, A Critical Comparison of some methods for interpolation of scattered data, Araştırma raporu, Naval Postgraduate School Monterey, California.
- Graupe, D., 2007, Principles of Artificial 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.
- İnal, C., Turgut, B. ve Yiğit, C., Ö., 2003, Lokal Alanlarda Jeoit Ondülasyonunun Belirlenmesinde Kullanılan Enterpolasyon Yöntemlerinin Karşılaştırılması, *Selçuk Üniversitesi Jeodezi ve Fotogrametri Mühendisliğinde 30, Yıl Sempozyumu, Ekim 2013*, Konya, Bildiriler Kitabı, 97-106.
- 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., 2009, Increasing the accuracy of neural network classification using refined training data. *Environmental Modelling and Software*, 24: 850-858.
- Kutoglu, H. S., 2006, Artificial Neural Networks versus Surface Polynomials for Determination of Local Geoid, *1st International Gravity Symposium*, İstanbul.
- 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*, 62, 87-92.
- 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.
- Öztemel, E., 2016, Yapay Sinir Ağları, *Papatya Bilim Üniversite Yayıncılığı*, İstanbul.
- 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 İn Mass Real Estate Appraisal, *Journal Of Real Estate Research*, 31-2: 147-164.
- Turgut, B., (2016), Gravite Değerlerinin Geri Yayılımlı Yapay Sinir Ağları ile Hesaplanması, *Afyon Kocatepe Üniversitesi Fen ve Mühendislik Bilimleri Dergisi*, 16, 660-664.
- Üstün, A., 2002, Bölgesel Ve Global Yükseklik Sistemlerinin Oluşturulmasında GPS'nin Katkısı Üzerine Bir İnceleme, Doktora Tezi, *Yıldız Teknik Üniversitesi Fen Bilimleri Enstitüsü*, İstanbul.

- Verbeurgt, J. 2018, Kişisel görüşme, Belçika Coğrafya Enstitüsü, Brüksel.
- Veronez, M. R., Thum, A. B., Souza G. C., 2006, A new method for obtaining geoidal undulations through Artificial, *7th International Symposium on Spatial Accuracy Assessment in Natural Resources and Environmental Sciences*, Lisbon, Portugal, 306-316.
- Yılmaz, İ. and Güllü, M., 2010, Georeferencing of historical maps using back propagation artificial neural network, *Experimental Techniques*, 36, 15-19
- Yılmaz, M., 2012, Jeodezik Nokta Hız Kestiriminde Yapay Sinir Ağlarının Kullanılabilirliği. Doktora Tezi, *Afyon Kocatepe Üniversitesi, Fen Bilimleri Enstitüsü*, Afyonkarahisar.



## ÖZGEÇMİŞ

### KİŞİSEL BİLGİLER

**Adı Soyadı** : Yaşar FİDANCI  
**Uyruğu** : Türkiye Cumhuriyeti  
**Doğum Yeri ve Tarihi** : Seydişehir/Konya 01.06.1989  
**Telefon** : 0542 339 7372  
**E-Posta** : yasar.fidanci@gmail.com

### EĞİTİM

Derece	Adı	İl	Bitirme Yılı
Lise	: Çağlayan Lisesi	Antalya	2006
Lisans	: Karadeniz Teknik Üniversitesi	Gümüşhane	2011
Yüksek Lisans	: Konya Teknik Üniversitesi	Konya	2019

### İŞ DENEYİMLERİ

Yıl	Kurum	Görevi
İlk Yapı	Özel sektör (inşaat)	Harita Mühendisi
Düzkar İnşaat	Özel sektör (inşaat)	Harita Etüt Şefi
Sty İnşaat	Özel sektör (inşaat)	Etüt Proje Şefi
Bergiz İnşaat	Özel sektör (inşaat)	Etüt Proje Şefi

### UZMANLIK ALANI

Jeodezi, Yapay Sinir Ağları, Yerel Jeoit Belirleme

### YABANCI DİLLER

İngilizce

### BELİRTMEK İSTEĞİNİZ DİĞER ÖZELLİKLER

#### YAYINLAR

Fidancı, Y. ve Abbak, R. A. (2019), Yerel Jeoit Belirlemede Yapay Sinir Ağlarının Farklı Nokta Yoğunluğundaki Performansı, *Gümüşhane Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, Kabul edildi.