



HARRAN ÜNİVERSİTESİ MÜHENDİSLİK DERGİSİ

HARRAN UNIVERSITY JOURNAL of ENGINEERING

e-ISSN: 2528-8733 (ONLINE)

URL: <http://dergipark.org.tr/humder>

Adıyaman İli için Yapay Sinir Ağları ile Geoit Belirleme

Geoid Determination with Artificial Neural Networks for Adıyaman Province

Yazar(lar) (Author(s)): Nihat DİNÇ¹, Mustafa ULUKAVAK²

¹ ORCID ID: 0000-0002-7185-3938

² ORCID ID: 0000-0003-2092-3075

Bu makaleye şu şekilde atıfta bulunabilirsiniz (To cite to this article): Dinç N., Ulukavak M., “Adıyaman İli için Yapay Sinir Ağları ile Geoit Belirleme”, *Harran Üniversitesi Mühendislik Dergisi*, 7(3): 181-192, (2022).

Erişim linki (To link to this article): <http://dergipark.org.tr/humder/archive>



Adıyaman İli için Yapay Sinir Ağları ile Geoit Belirleme

Nihat DİNÇ¹, Mustafa ULUKAVAK²

¹Adıyaman Üniversitesi, Kahta Meslek Yüksekokulu, Mimarlık ve Şehir Planlama Bölümü, Kahta/Adıyaman

²Harran Üniversitesi, Mühendislik Fakültesi, Harita Mühendisliği Bölümü, Haliliye/Şanlıurfa

Öz

Geoit, yerin gravite alanının ortalama deniz seviyesine en iyi uyum eş potansiyel yüzeydir. Geoidin yüksek hassasiyette hesaplanması jeodezide önemlidir. Geoit belirleme yatay konumu bilinen noktalarda, geoit yüksekliğini analog veya sayısal olarak elde edilmesinin sağlayacak şekilde verilerin modellenmesidir. Bu çalışmada geoit modelinin yapay sinir ağları ile belirlenmesi ve kullanılabilirliği araştırılmıştır. Çalışma alanı olarak Adıyaman İli mücavir alan sınırını kapsayacak 165 km² alan içinde 10,000 adet poligon noktasından 874 adet poligon noktası homojen dağılımda seçilerek eğitim ve test verisi olarak seçilmiştir. 5 eğitim fonksiyonu ve 15 farklı katman sayısı ile toplam 75 deney yapılmıştır. Elde edilen düşey konum doğruluğunun Büyük Ölçekli Harita ve Harita Bilgileri Üretimi Yönetmeliği'nde belirlenen sınır değerinin (± 5 cm) altında elde edildiği görülmüştür.

Makale Bilgisi

Başvuru: 21/10/2022

Yayın: 30/12/2022

Anahtar Kelimeler

Geoit Belirleme
Yapay Sinir Ağları
Ortometrik Yükseklik
Elipsoit Yüksekliği

Keywords

Geoid Determination
Artificial Neural Networks
Orthometric Height
Ellipsoid Height

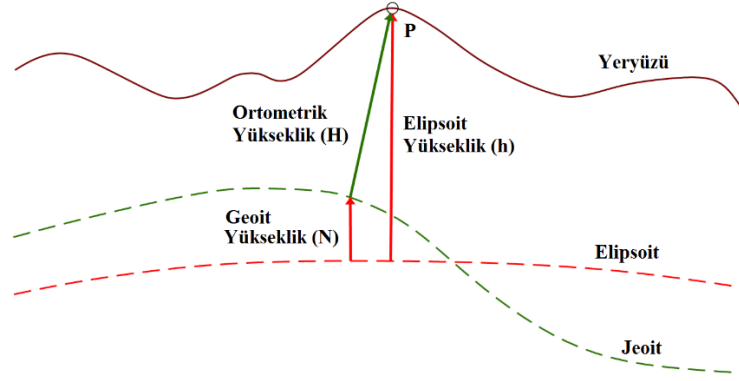
Geoid Determination with Artificial Neural Networks for Adıyaman Province

Abstract

The geoid is the equipotential surface that best fits the mean sea level of the Earth's gravitational field. High precision calculation of the geoid is important in geodesy. Geoid determination is the modeling of data in such a way that the geoid height can be obtained analog or digitally at points whose horizontal position is known. In this study, the determination and usability of the geoid model with artificial neural networks were investigated. As the study area, 874 polygon points out of 10,000 polygon points within an area of 165 km² which will cover the adjacent area border of Adıyaman Province, were selected in a homogeneous distribution and selected as training and test data. A total of 75 experiments were conducted with 5 training functions and 15 different layers. It has been observed that the vertical position accuracy obtained is below the limit value (± 5 cm) determined in the Regulation on Large-Scale Map and Map Information Production.

1. GİRİŞ (INTRODUCTION)

Jeodezi, üç boyutlu ve zamana değişkenlik gösteren, yerin gravite alanı ile yeryuvarının alanını hesaplayarak topoğrafyanın ölçülmesi ve haritaya çizilmesi ile uğraşan bir bilim dalıdır [1]. Geoit matematiksel olarak ifade edilmeyen karmaşık bir yüzey olarak tanımlanabilir. Geoit yüksekliği, ortometrik yükseklikler için referans yüzeyi olmasından dolayı jeodezi biliminde önemlidir [2]. Geoit belirleme yatay konumu bilinen noktalarda, geoit yüksekliğini analog veya sayısal olarak elde edilmesinin sağlayacak şekilde verilerin modellenmesidir. Geoit yüksekliği hassas bir şekilde belirlenebilirse, ortometrik yüksekliklerden elipsoit yüksekliklerin hesaplanması veya elipsoit yüksekliklerinden ortometrik yüksekliklerin hesaplanması daha hassas yapılabilir [3]. GPS ile ölçülen elipsoit yüksekliği ortometrik yüksekliklere dönüştürebilmek için geoit yüksekliklerin bilinmesi gerekmektedir [4]. Son yıllarda GPS teknolojisi ile üretilen elipsoit yükseklik topoğrafyayı yansıtmadığından dolayı geoit yüksekliğine ihtiyaç artmaktadır [5].



Şekil 1: Ortometrik ve Elipsoit yüksekliği ([8]'dan Değiştirilerek).

Elipsoit yüksekliği (h), GPS ölçüleri ile bir koordinat sisteminin başlangıç elipsoidi kullanılarak belirlenir [6]. Fiziksel yeryüzü ile elipsoit yüksekliği arasındaki ilişkinin kurulduğu geoit yükseklik Şekil 1'de verilmiştir. Burada geoit yükseklik (N), elipsoit ile jeoit arasındaki uzaklık; ortometrik yükseklik (H), fiziksel yeryüzü ile jeoit arasındaki uzaklık ve elipsoit yükseklik (h), fiziksel yeryüzü ile elipsoit arasındaki uzaklık olarak ifade edilir [7,8].

$$N = h - H \quad (1)$$

Eşitlik (1)'de geoit yüksekliğinin elipsoit ve ortometrik yükseklikler arasındaki ilişkisi gösterilmiştir. Bu çalışmada, yapay sinir ağları ile geoit belirleme yöntemi araştırılmıştır. 2. bölümde yapay sinir ağlarından, özelliklerinden, uygulama için kullanılan çalışma verisinden ve çalışma alanından bahsedilmiştir. 3. bölümde ise yapılan uygulamaya ait bulgular tablo ve grafikler ile birlikte verilmiştir. Son bölümde ise çalışmaya ait sonuçlardan bahsedilmiştir.

2. MATERYAL VE YÖNTEM (MATERIAL AND METHOD)

2.1. Yapay Sinir Ağları

Yapay sinir ağları insan beyninin temel özellikleri olan öğrenme fonksiyonu ile bilgi keşfetme ve türetme yeteneklerini hiçbir yardım almayarak otomatik olarak geliştirilen bilgisayar sistemleridir [9,13]. Bilgi keşfetme ve türetme işlemleri örneklerle gerçekleştirirler. Ağlar birbirlerine bağlı yapay sinir hücrelerinden oluşur [11].

Yapay sinir ağlarının tarihçesi insanların biyolojik sinir sistemleri konusu ile ilgilenerek elde edilen bilgilerin bilgisayar sistemlerine uygulaması ile başlamaktadır [11]. Yapay sinir ağları ile insan beyninin fonksiyonlarını konu alan ilk çalışma 1870 yılında yayınlanmıştır [2]. 1940 yılından önce yapay sinir ağlar konusunda yayın değeri olmayan bazı çalışmalar yapılmıştır. İlk yapay sinir ağları modeli 1943 yılında Walter Pitts ve Warren McCulloch tarafından modellenmiştir [12]. Yapay sinir ağları konusu 1970 yılı bir dönüm noktası olduğu görülmektedir. 1970 yılından itibaren yapay sinir ağları gelişme göstermiştir [13].

Yapay sinir ağlarında amaç matematiksel fonksiyonlar ifade edilmeyen veya karmaşık algoritmalara sahip bir problemi çözmek için kullanılır. Bundan dolayı çevreden gelen etkileri okuyan, tepki veren ve öğrenen bir sistemdir [12]. İnsan beyniyle aynı şekilde; Öğrenme, sınıflandırma, ilişkilendirme, optimizasyon ve genelleme gibi görevleri başarılı bir şekilde yapmaktadır [10].

2.2. Yapay Sinir Ağlarının Özellikleri

Yapay sinir ağlarının özellikleri uygulanan modele göre değişiklik göstermektedir. Yapay sinir ağlarının genel özellikleri; bilgisayar öğrenmesini sağlar, bilgilerin saklanması kolaydır, denemeler üzerinden öğrenilir, eğitimleri ve performansları test edilerek güvenle çalışabilmesi sağlanır, bilgi eksikliğiyle

çalışabilir, hata sınırına sahiptir, belirsiz ve eksik bilgi ile çalışabilir, dereceli bozulma gösterir ve sadece sayısal bilgi ile çalışabilir [10].

Bu özelliklere ek olarak geliştirilen her modelin kendisine özgü özellikleri de olabilir. Bu özelliklere göre yapay sinir ağlarının bilgisayar teknolojisine avantajlı katkılarının olduğu görülmektedir. Yazılım teknolojisi ile çözüm üretilmeyen problemlerin yapay sinir ağları çözüm üretilebileceği görülmektedir. Yapay sinir ağları normal olmayan, eksik bilgiye ve belirsiz bilgilere sahip problemleri çözme tekniğidir [14].

Yapay sinir ağlarının bu özellikleri yanında önemli dezavantajlarından bahsedecek olursak; donanıma bağlı çalışması, modelle uygun ağ yapılarının belirlenmesi deneme ve yanılma yolu ile belirlenmesi önemli bir sorundur [2]. Problem için uygun bir ağ oluşturulmaz ise performansı düşük çözümlerin veya problemlerin çözülmemesi söz konusu olabilir. Yapay sinir ağlarının öğrenme katsayısı proses elemanı sayısı ve katman sayısı gibi parametre değerlerinin belirlenmesinde belli bir kural olmaması ayrı bir problemdir. Buda iyi çözümler bulmayı zorlaştıran bir durumdur. Yapay sinir ağları yukarıda belirtildiği gibi sadece sayısal bilgi ile çalışmaktadır. Problemlerin çözümü için verilerin sayısal hale dönüştürülmesi gerekir. Sayısal hale dönüştürülen verilerle ağ eğitiminin ne kadar sürede tamamlanacağına ilişkin geliştirilmiş bir yöntem bulunmamaktadır ve bu da kullanıcının becerisine bağlıdır [14].

2.3. Yapay Sinir Ağlarının Uygulama Alanları

Uygulama alanlarında yapay sinir ağlarını sınırlamak çok zordur. Yapay sinir ağlarını bu derece güncel yapan, eksik bilgi ile çalışabilmesi ve verileri işleyebilmesidir. Özellikle birçok sayıda veriyi işleme gerektiren problemlerde çok avantajlı çözümler elde edilebilir. Bu nedenlerden dolayı yapay sinir ağlarını kullanılabilecek birçok farklı alan vardır. Bir problemin yapay sinir ağı ile çözülmesi için aşağıdaki maddeleri sağlaması gerekir [2,9].

- Yalnızca yapay sinir ağları ile kolay çözümler üretebilme imkânı var mı?
- Yapay sinir ağlarına olan ihtiyaç, farklı çözüm yollarının olması durumunda, çok daha etkili ve pratik bir çözüm üretebiliyor mu?

2.4. İleri Beslemeli Yapay Sinir ağları

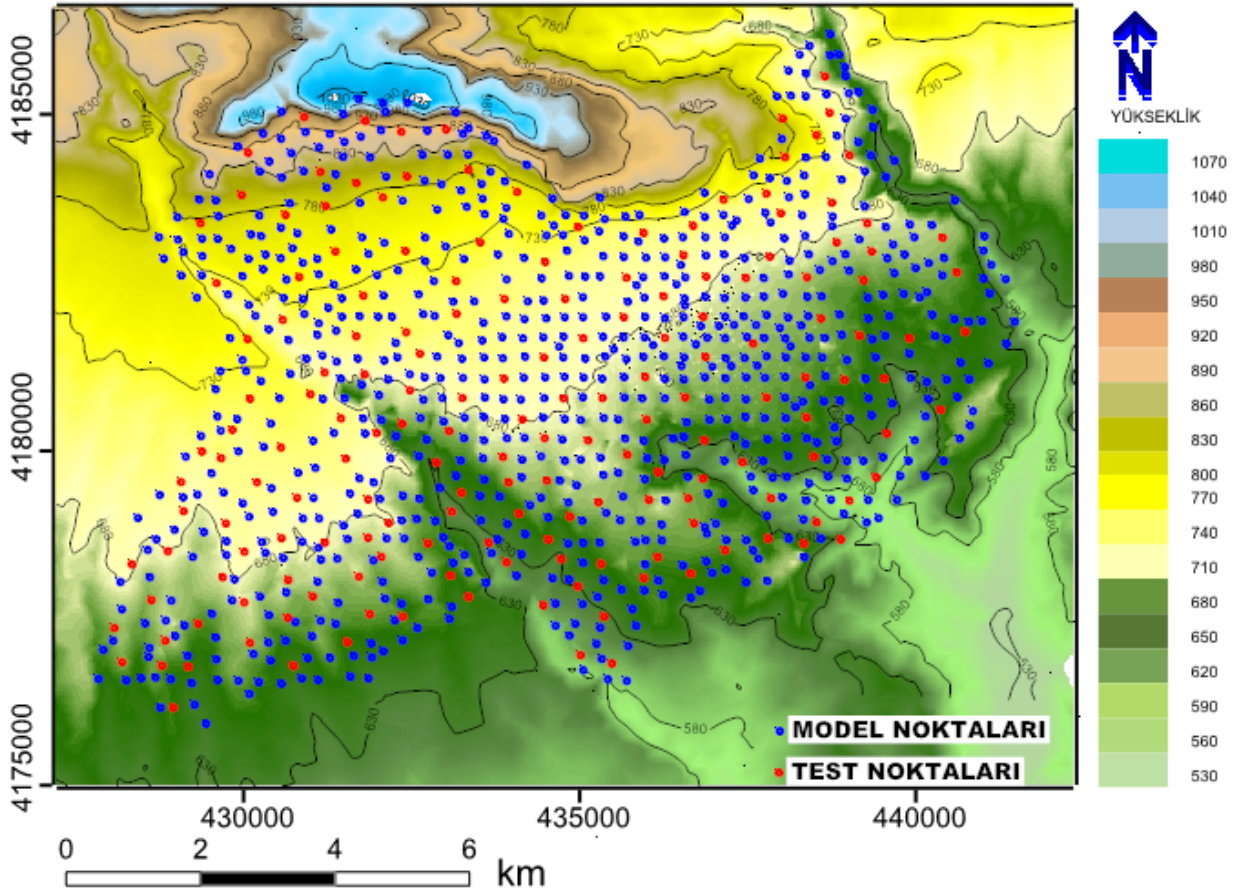
İleri beslemeli yapay sinir ağlarında akışın girdi katmanından çıkış katmanına doğru gerçekleştiği ağ şeklindedir. Katmandan sadece ileri katmana doğru bağ kurarak gerçekleşmektedir. Bir katmanın girişine gelen nöronların bilgiler değişime uğramadan diğer katmandaki nöronlara diğer bir deyişle gizli katmandaki hücrelere girdi olarak iletilir [9].

2.5. Veriler

Çalışma bölgesine ait verileri Adıyaman Belediyesi'nin yaptığı halihazır çalışmasına ait poligon ve nirengilerinden elde edilmiştir [16]. Çalışma alanında 874 adet poligon noktasından oluşmaktadır. Noktaların Uluslararası Yersel Referans Çerçevesi ITRF96 (Universal Transversal Merkator: UTM) projeksiyon koordinat değerleri (x, y), ortometrik yükseklik (H) ve elipsoidal yükseklik (h) değerlerinden oluşmaktadır. Elipsoit yükseklik ve ortometrik yükseklik değerlerine göre geoid yükseklik değişimi yaklaşık bir metre (~1 m) olarak hesaplanmıştır. 874 adet noktadan oluşan çalışma verilerin %80'i eğitim ve %20'si test verileri olarak geoid modeli belirlenecektir.

2.6. Çalışma Alanı

Adıyaman Belediyesi mücavir alan sınırlarını kapsayan yaklaşık olarak $37,72^\circ < \varphi < 37,81^\circ$ kuzey ve $38,17^\circ < \lambda < 38,33^\circ$ doğu coğrafi koordinatları arasında kalmaktadır. Çalışma alanı 11 km x 15 km boyutlarında olup yüzölçümü yaklaşık 165 km²'dir. Çalışma bölgesine ait eğitim ve test verilerinin konumlarını gösteren harita Şekil 2'de verilmiştir.



Şekil 2: Çalışma bölgesi ve uygulama noktalarının konumlarını gösteren harita

Şekil 2’de görüldüğü gibi bölgenin ortometrik yükseklikleri 558 m ile 1083 m arasında değişiklik göstermektedir. Arazi topoğrafyasına ait yüksekliklerin değişimi fazla olduğu için çalışma bölgesi olarak Adıyaman ili seçilmiştir.

2.7. Araştırma

Belli bir problem için hangi eğitim fonksiyonunun daha hızlı çözüm sağlayacağını belirlemek zordur. Problemin karmaşıklığı, eğitim noktalarının sayısı, ağıdaki ağırlıkların ve önyargıların sayısı, hataların hedefi ve ağı örüntü tanıması için kullanılabilmesi (ayır edici analiz) gibi birçok faktörlere bağlıdır. İleri beslemeli ağlar altı farklı problem üzerinde eğitilir. Problemlerden üçü örüntü tanıma kategorisine girer ve diğer üçü fonksiyon yaklaşımı kategorisine girer. Problemlerden ikisi basit “oyuncak” problemleri, diğer dördü ise “gerçek dünya” problemleridir. Çeşitli farklı mimarilere ve karmaşıklığa sahip ağ modelleri kullanılır ve ağlarda çeşitli farklı doğruluk değerlerine göre eğitilir [15].

Yapılan çalışmada Büyük Ölçekli Harita ve Harita Bilgileri Üretim Yönetmeliğine (BÖHHBÜY) göre karesel ortalama hatanın (KOH) ± 5 cm’nin altında olması gerekiyor [17].


3. BULGULAR VE TARTIŞMA (RESULTS AND DISCUSSION)

Bu çalışmanın amacı geoit yüksekliğini ileri beslemeli yapay sinir ağları kullanılarak 5 farklı eğitim fonksiyonu ve 15 farklı katman sayısı ile eğiterek en hızlı ve hassas olan fonksiyonu araştırmaktır. Çalışmada bölgede 874 adet poligon noktası kullanılmıştır.

Tablo 1: Uygulamadaki eğitim ve test verilerinin sayısı

Uygulama No	Eğitim Veri Sayısı	Test Veri Sayısı	Nokta Dağılımı
1	700	174	Homojen

Çalışma bölgesindeki noktaların homojen dağılımı Netcad programı yardımı ile Adıyaman Belediyesi'nden alınan 10,000 adet nokta arasından 250 m × 250 m ölçülerinde karelej oluşturularak ve karelajlara en yakın noktaların uygulama noktası olarak seçilmesiyle belirlenmiştir (Şekil 3).

**Şekil 3:** Uygulama noktalarının homojen dağılım olarak seçilmesi


Yapay sinir ağların modelini oluşturmak için MATLAB R2022b yazılımı kullanılmıştır. Yapay sinir ağı uygulaması için MATLAB®'ın Neural Network ara yüzünde değerlendirme yapılmıştır. Yapay sinir ağları model oluşturmak için belli bir kural yoktur. Model için belirlenecek ara katman sayısı, toplama fonksiyonu, öğrenme algoritması, iterasyon sayısı, uygulamaya alınan veri sayısı gibi değişkenler birçok deneme yapılarak belirlenebilmektedir. Bu sebeplerden dolayı verilerin çözümü için çok sayıda uygulama yapılarak süreç sonunda elde edilen hata değerlerinin minimum olanı optimum yöntem olarak değerlendirilir.

Yapay sinir ağları modelini oluştururken; ideal eğitim fonksiyonunun (Training Function) belirlenebilmesi için toplam 5 farklı (*trainbfg*, *trainbr*, *trainlm*, *trainrp* ve *trainscg*) fonksiyonda deneme yapılmıştır. Her fonksiyon için katman sayısı (Number of Layers) ise 15 farklı (1, 2, 3, 4, 5, 6, 7, 8, 9, 10, 20, 30, 40, 50, 100) parametre ile ayrı ayrı değerlendirilmiştir.

Tablo 2: *Trainbfg* fonksiyonunun katman sayılarına göre karşılaştırması (cm)

Katman Sayısı	KOH Eğitim	KOH Test	Test seti Max. hata	Test seti Min. hata
1	0,44	0,20	2,13	0,01
2	0,36	0,18	2,02	0,00
3	0,40	0,19	2,18	0,01
4	0,39	0,20	2,15	0,01
5	0,43	0,18	2,10	0,01
6	0,40	0,17	1,98	0,01
7	0,50	0,22	2,38	0,01
8	0,40	0,17	1,85	0,01
9	0,38	0,17	1,89	0,01
10	0,41	0,20	2,30	0,01
20	0,37	0,19	2,09	0,01
30	0,42	0,21	2,55	0,01
40	0,41	0,19	2,07	0,01
50	0,46	0,17	2,05	0,01
100	0,39	0,20	2,42	0,01

Tablo 2’de *trainbfg* fonksiyonunun katman sayılarına göre incelendiğinde eğitim verilerinde en düşük KOH değeri $\pm 0,36$ cm olan katman sayısı 2 olan denemedir. Test verilerinde ise en düşük KOH değeri $\pm 0,17$ cm olan katman sayısı 6, 8, 9 ve 50 olan denemelerdir.


**Şekil 4:** *Trainbfg* fonksiyonunun katman sayılarına göre eğitim ve test verilerinin KOH grafiği

Şekil 4’de *trainbfg* KOH grafiği incelendiğinde eğitim KOH değerlerinin $\pm 0,36$ - $0,50$ cm değerleri arasında değiştiği, test KOH değerlerinin ise $\pm 0,17$ - $0,20$ cm değer arasında değiştiği görülmüştür. Sonuçların BÖHHBÜY’e göre çok düşük çıktığı belirlenmiştir.

Tablo 3: *trainbr* fonksiyonun katman sayılarına göre karşılaştırması (cm)

Katman Sayısı	KOH Eğitim	KOH Test	Test seti Max. hata	Test seti Min. hata
1	0,31	0,18	2,25	0,01
2	0,30	0,17	1,87	0,00
3	0,29	0,17	1,88	0,01
4	0,31	0,18	1,72	0,01
5	0,29	0,17	2,05	0,01
6	0,30	0,17	2,12	0,01
7	0,32	0,19	2,23	0,01
8	0,29	0,18	2,16	0,01
9	0,39	0,19	2,17	0,01
10	0,29	0,17	1,98	0,01
20	0,29	0,18	2,15	0,01
30	0,28	0,16	1,89	0,01
40	0,29	0,17	1,73	0,01
50	0,35	0,18	2,33	0,01
100	0,29	0,17	1,89	0,01

Tablo 3’de *trainbr* fonksiyonun katman sayılarına göre incelendiğinde eğitim verilerinde en düşük KOH değeri $\pm 0,28$ cm olan katman sayısı 30 olan denemedir. Test verilerinde ise en düşük KOH değeri $\pm 0,16$ cm olan katman sayısı 30 olan denemedir.

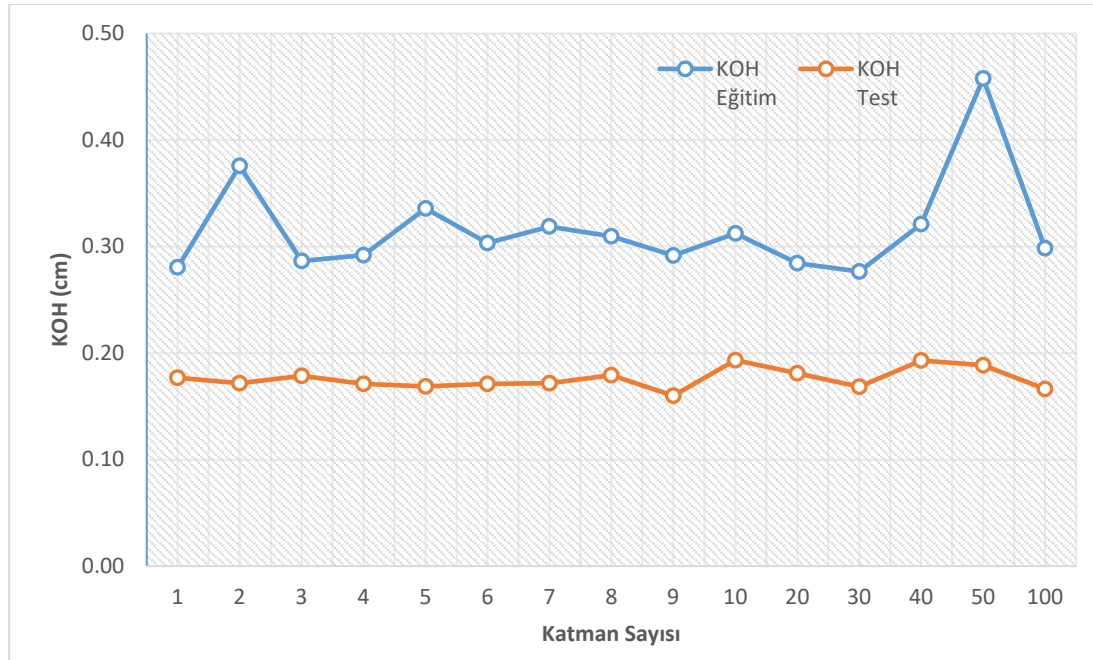
**Şekil 5:** *Trainbr* fonksiyonunun katman sayılarına göre eğitim ve test verilerinin KOH grafiği

Şekil 5’de *trainbr* KOH grafiği incelendiğinde eğitim KOH değerlerinin $\pm 0,28$ - $0,39$ cm değer arasında değiştiği, test KOH değerlerinin ise $\pm 0,16$ - $0,19$ cm değer arasında değiştiği görülmüştür. Sonuçların BÖHHBÜY’e göre çok düşük çıktığı belirlenmiştir.

Tablo 4: *Trainlm* fonksiyonunun katman sayılarına göre karşılaştırması (cm)

Katman Sayısı	KOH Eğitim	KOH Test	Test seti Max. hata	Test seti Min. hata
1	0,28	0,18	2,11	0,00
2	0,38	0,17	2,01	0,00
3	0,29	0,18	2,14	0,00
4	0,29	0,17	2,09	0,00
5	0,34	0,17	1,67	0,00
6	0,30	0,17	1,93	0,00
7	0,32	0,17	2,07	0,00
8	0,31	0,18	1,94	0,00
9	0,29	0,16	7,14	0,00
10	0,31	0,19	2,38	0,00
20	0,28	0,18	2,04	0,00
30	0,28	0,17	2,00	0,00
40	0,32	0,19	2,43	0,00
50	0,46	0,19	2,26	0,00
100	0,30	0,17	1,80	0,00

Tablo 4’de *trainlm* fonksiyonunun katman sayılarına göre incelendiğinde eğitim verilerinde en düşük KOH değeri $\pm 0,28$ cm olan katman sayısı 1 ve 20 olan denemelerdir. Test verilerinde ise en düşük KOH değeri $\pm 0,16$ cm olan katman sayısı 9 olan denemedir.


**Şekil 6:** *Trainlm* fonksiyonunun katman sayılarına göre eğitim ve test verilerinin KOH grafiği

Şekil 6’de *trainlm* KOH grafiği incelendiğinde eğitim KOH değerlerinin $\pm 0,28$ - $0,46$ cm değer arasında değiştiği, test KOH değerlerinin ise $\pm 0,16$ - $0,19$ cm değer arasında değiştiği görülmüştür. Sonuçların BÖHHBÜY’e göre çok düşük çıktığı belirlenmiştir.

Tablo 5: *Trainrp* fonksiyonun katman sayılarına göre karşılaştırması (cm)

Katman Sayısı	KOH Eğitim	KOH Test	Test seti Max. hata	Test seti Min. hata
1	0,69	0,26	2,66	0,00
2	0,72	0,22	2,08	0,00
3	0,56	0,21	2,26	0,00
4	0,71	0,26	2,85	0,00
5	0,62	0,21	1,82	0,01
6	0,59	0,20	1,94	0,00
7	0,73	0,23	3,41	0,00
8	0,65	0,23	2,32	0,01
9	0,68	0,29	2,50	0,00
10	0,68	0,20	2,18	0,01
20	0,58	0,20	2,82	0,00
30	0,61	0,24	1,94	0,00
40	0,56	0,23	2,30	0,00
50	0,64	0,27	2,79	0,00
100	0,62	0,20	2,04	0,00

Tablo 5’de *trainrp* fonksiyonun katman sayılarına göre incelendiğinde eğitim verilerinde en düşük KOH değeri $\pm 0,56$ cm olan katman sayısı 3 ve 40 olan denemelerdir. Test verilerinde ise en düşük KOH değeri $\pm 0,20$ cm olan katman sayısı 6, 10, 20 ve 100 olan denemelerdir.


**Şekil 7:** *Trainrp* fonksiyonunun katman sayılarına göre eğitim ve test verilerinin KOH grafiği

Şekil 7’de *trainrp* KOH grafiği incelendiğinde eğitim KOH değerlerinin $\pm 0,56-0,73$ cm değer arasında değiştiği, test KOH değerlerinin ise $\pm 0,20-0,29$ cm değer arasında değiştiği görülmüştür. Sonuçların BÖHHBÜY’e göre çok düşük çıktığı belirlenmiştir.

Tablo 6: *Trainscg* fonksiyonunun katman sayılarına göre karşılaştırması (cm)

Katman Sayısı	KOH Eğitim	KOH Test	Test seti Max hata	Test seti Min hata
1	0,60	0,24	2,28	0,01
2	0,73	0,24	2,09	0,00
3	0,77	0,27	2,89	0,00
4	0,73	0,29	2,80	0,00
5	0,83	0,25	3,20	0,00
6	0,75	0,22	3,05	0,00
7	0,62	0,23	2,47	0,01
8	0,71	0,25	2,34	0,00
9	0,65	0,20	1,96	0,00
10	0,72	0,21	2,77	0,00
20	0,82	0,20	3,05	0,00
30	0,68	0,27	2,14	0,01
40	0,67	0,24	2,61	0,01
50	0,74	0,30	3,00	0,01
100	0,67	0,23	1,99	0,01

Tablo 6’de *trainscg* fonksiyonunun katman sayılarına göre incelendiğinde eğitim verilerinde en düşük KOH değeri $\pm 0,60$ cm olan katman sayısı 1 olan denemelerdir. Test verilerinde ise en düşük KOH değeri $\pm 0,20$ cm olan katman sayısı 9 ve 20 olan denemelerdir.

**Şekil 8:** *Trainscg* fonksiyonunun katman sayılarına göre eğitim ve test verilerinin KOH grafiği

Şekil 8’de *trainscg* KOH grafiği incelendiğinde eğitim KOH değerlerinin $\pm 0,60$ - $0,83$ cm değer arasında değiştiği, test KOH değerlerinin ise $\pm 0,20$ - $0,30$ cm değer arasında değiştiği görülmüştür. Sonuçların BÖHHBÜY’e göre çok düşük çıktığı görülmüştür. 5 farklı fonksiyon incelendiğinde test verilerinin KOH değerleri $\pm 0,16$ - $0,30$ cm değerleri arasında değiştiği görülmüştür. Bu değerlerde BÖHHBÜY’e göre daha iyi duyarlılıkta olduğu belirlenmiştir.

4. SONUÇ (CONCLUSION)

Bu çalışmada yapay sinir ağları ile yerel geoit modeli belirleme araştırması yapılmıştır. Uygulamada yaklaşık 165 km²'lik alanda 874 adet poligon noktası kullanılmış ve MATLAB® ortamında yapay sinir ağları modülü altındaki beş farklı eğitim fonksiyonu kullanılarak oluşturulan geoit modellerinin doğruluğu araştırılmıştır. Geoit modellerin KOK'unu BÖHHBÜY'e göre ± 5 cm'den küçük olarak belirlenmiştir. Yapay sinir ağları yöntemi ile yapılan çalışmada bütün denemelerin KOK değerleri $\pm 0,16$ cm ile $\pm 0,30$ cm arasında elde edilerek oldukça hassas bir model belirlenmiştir. Böylelikle söz konusu yöntemin bu tür çalışmalarda oldukça başarılı sonuçlar elde edilmesine olanak tanıdığı ortaya koyulmuştur. Bu çalışmada en ideal KOK değeri $\pm 0,16$ cm ile *trainbr* fonksiyonunda 30 katman sayısı ile *trainlm* fonksiyonunda da 9 katman sayısı ile ortaya çıkarılmıştır. Bütün katman sayılarına bakıldığında ise *trainbr* ve *trainlm* fonksiyonları $\pm 0,16$ cm ile $\pm 0,19$ cm arasında değerler almıştır. *Trainbr* ve *trainlm* fonksiyonu yapay sinir ağları ile geoit modelleme çalışmalarında kullanılabilir hassasiyette çıktılar verebilmektedir. Yapay sinir ağları ile elde edilen bu sonuçlar, Adıyaman İli sınırları içinde kullanılabilir niteliktedir.

TEŞEKKÜR

Makale çalışmasında sırasında kullanılan verileri tarafımıza sağlayan Adıyaman Belediyesi'ne teşekkürlerimizi sunarız.

ÇIKAR ÇATIŞMASI

Makale yazarları aralarında herhangi bir çıkar çatışması olmadığını beyan ederler.

KAYNAKLAR

- [1] R. A. Abbak, Fiziksel Jeodezi Teori ve Uygulama, Atlas Akademi Yayıncılık, Konya, 2018
- [2] Y. Fidancı, Yapay Sinir Ağları İle Jeoit Belirleme, Yüksek lisans Tezi, Konya Teknik Üniversitesi, Lisansüstü Eğitim Enstitüsü, 2019.
- [3] M. Yılmaz, E. Ersoy, İstanbul Metropolitan Alanında Geoit Araştırması, itüdergisi/d Mühendislik, 5:3 (2006) 107-114.
- [4] N. Yılmaz, Testing The Performance Of Spatial Interpolation Methods Used For Geoid Modeling, Fresenius Environmental Bulletin 26:3 (2017) 2359-2367
- [5] N. Yılmaz, Jeoid yüksekliklerinin belirlenmesinde ağırlıklı ortalama ve polinomlarla enterpolasyon yöntemlerinin karşılaştırılması, Dicle Üniversitesi Mühendislik Fakültesi Mühendislik Dergisi, 10:2 (2019) 743-754.
- [6] H. Kurtoğlu, Artificial Neural Network versus Surface Polynomials for Determination of Local Geoid, 1st International Gravity Symposium, 2015.
- [7] M. Albayrak, M.T. Özlüdemir, M. M. Aref, K. Halicioglu, Determination of Istanbul geoid using GNSS/levelling and valley cross levelling data, Geodesy and Geodynamics, 11:3 (2020) 163-173.
- [8] E. Akiz, M. Yerci, Jeoit Kullanarak Elipsoit Yüksekliklerinden Ortometrik Yükseklik Belirleme Yöntemlerinin Doğruluk Araştırması, Harita Dergisi, S.141 (2009) 13-25.
- [9] K. Öztürk, M. E. Şahin, Yapay Sinir Ağları Ve Yapay Zeka'ya Genel Bir Bakış, Takvim-i Vekayi, 2018.
- [10] E. Öztemel, Yapay Sinir Ağları, Papatya Bilim Üniversitesi Yayıncılığı, İstanbul, 2016.
- [11] M. T. Ballı, Yapay Sinir Ağları İle Talep Tahmini Ve Gıda Sektöründe Uygulanması, Yüksek lisans Tezi, Yıldız Teknik Üniversitesi, Fen Bilimleri Enstitüsü, 2014.
- [12] M. F. Keskenler, E. F. Keskenler, Geçmişten Günümüze Yapay Sinir Ağları ve Tarihçesi, Takvim-i Vekayi, 2017.
- [13] Y. Fidancı, R. A. Abbak, Yerel Jeoit Belirlemede Yapay Sinir Ağlarının Farklı Nokta Yoğunluğundaki Performansı, Gümüşhane Üniversitesi Fen Bilimleri Dergisi, 9:3 (2019) 486-495.

- [14] Z. Şen, Yapay Sinir Ağları, Su Vakfı, 2004.
- [15] Mathworks. <https://www.mathworks.com/help/deeplearning/ug/choose-a-multilayer-neural-network-training-function.html> (Erişim: 9 Ekim 2022).
- [16] Anonim, Adıyaman Belediyesi Fiziksel Arşivinden Sağlanan veriler (Yayınlanmamış 2022).
- [17] Anonim, Büyük Ölçekli Harita ve Harita Bilgileri Üretim Yönetmeliği, R.G. 26.06.2018 Cilt. 59