

## Çok Katmanlı Algılayıcı Yapay Sinir Ağı ile Jeodezik Elipsoidal Koordinatların $(\varphi, \lambda, h)$ 3 Boyutlu Global Kartezyen Koordinatlara $(X, Y, Z)$ Dönüşümü

*Transformation of Geodetic Ellipsoidal Coordinates  $(\varphi, \lambda, h)$  to 3 Dimensional Global Cartesian Coordinates  $(X, Y, Z)$  with Multi-layer Perceptron Artificial Neural Network*

**Berkant KONAKOĞLU\***

*Amasya Üniversitesi, Teknik Bilimler Meslek Yüksekokulu, Harita ve Kadastro Programı, 05100, Amasya*

• Geliş tarihi / Received: 31.03.2020

• Düzeltilecek geliş tarihi / Received in revised form: 23.05.2020

• Kabul tarihi / Accepted: 02.06.2020

### Öz

Jeodezik elipsoidal koordinatlar  $(\varphi, \lambda, h)$  ile üç boyutlu (3B) global kartezyen koordinatlar  $(X, Y, Z)$  arasındaki dönüşüm işlemi sıklıkla karşılaşılan bir problemdir. Bu dönüşüm problemini çözmek için sadece bir yöntem bulunmuştur. Mevcut araştırmalar incelendiğinde jeodezik elipsoidal koordinatlardan 3B global kartezyen koordinatlara dönüşüm yöntemine alternatif olabilecek tekniklerin uygulanması ve test edilmesi konusunda tam olarak değinilmediği belirlenmiştir. Bu çalışmanın amacı çok katmanlı algılayıcı yapay sinir ağı (ÇKAYSA) kullanarak jeodezik elipsoidal koordinatlardan 3B global kartezyen koordinatlara dönüşüm yönteminin performansını araştırmaktır. Tahmin için Türkiye Ulusal Temel GPS Ağı'na (TUTGA) ait 594 noktalı veri seti kullanılmıştır. Yapılan çok sayıda denemeler sonucu eğitim algoritması olarak Bayesian Regulation ve gizli katman sayısı 2 olarak belirlenmiştir. ÇKAYSA modellerinin performans değerlendirilmesi için karesel ortalama hata (KOH), ortalama mutlak hata (OMH) ve belirlilik katsayısı ( $R^2$ ) kriterleri kullanılmıştır. Test sonuçlarına göre ÇKAYSA ile 3B global kartezyen koordinatların bileşenleri için KOH değeri 0.4536 cm ile 0.9411 cm arasında, OMH değeri 0.3883 cm ile 0.8165 cm arasında değişim göstermiş, tüm modeller için  $R^2$  değeri 0.9999 olarak hesaplanmıştır. Sonuçları daha detaylı incelemek için tahmin edilen değerler ile hesaplanan değerler arasındaki fark değerleri hesaplanmıştır. Buna göre, fark değerlerinin az sayıda veri hariç sıfır değerine oldukça yakın olduğu görülmüştür. Söz konusu istatistiksel kriterlere göre, bu çalışmada kullanılan ÇKAYSA'nın klasik koordinat dönüşüm yöntemine alternatif olarak kullanılabilir bir yöntem olduğunu sonucuna varılmıştır.

**Anahtar kelimeler:** Çok Katmanlı Algılayıcı Yapay Sinir Ağı, Jeodezik Elipsoidal Koordinatlar, Koordinat Dönüşümü, 3B Global Kartezyen Koordinatlar

### Abstract

The problem of transformation between geodetic ellipsoidal coordinates  $(\varphi, \lambda, h)$  and three-dimensional (3D) global Cartesian coordinates  $(X, Y, Z)$  is a common one. Only one method for solving this transformation problem has been found. An examination of the current studies reveals that the application and testing of possible alternative techniques for transforming geodetic ellipsoidal coordinates to 3D global Cartesian coordinates have not been fully addressed. The aim of this study was to investigate the performance of a method of transforming geodetic ellipsoidal coordinates to 3D global Cartesian coordinates using a multilayer perceptron artificial neural network (MLP-ANN). For the prediction, 594-point datasets of the Turkish National Fundamental GPS Network (TNPGN) were used. As a result of many trials, the Bayesian Regulation was determined as the training algorithm and the number of hidden layers was 2. The mean squared error (MSE), mean absolute error (MAE), and coefficient of determination ( $R^2$ ) were used for the performance evaluation of the MLP-ANN model. According to the test results, the MSE value for the components of the MLP-ANN and the 3D global Cartesian coordinates varied between 0.4536 cm and 0.9411 cm, the MAE value ranged between 0.3883 cm and 0.8165 cm, and the  $R^2$  value was calculated as 0.9999 for all models. To examine the results in more detail, the difference between the estimated values and the calculated values was determined. Accordingly, it was found that the difference in the values was quite close to zero except for a few number of data. According to these statistical criteria, it was concluded that the MLP-ANN used in this study could be used as an alternative to the classical coordinate transformation method.

**Keywords:** Multi-layer Perceptron Artificial Neural Network, Geodetic Ellipsoidal Coordinates, Coordinate Transformation, 3B Global Cartesian Coordinates.

\*Berkant KONAKOĞLU; berkantkonakoglu@gmail.com, Tel: (0462) 377 27 78, orcid.org/0000-0002-8276-587X

## 1. Giriş

Dünya yüzeyinin üstünde veya altında, sabit ve sabit olmayan nesnelerin konumlarını belirleyen küresel navigasyon uydu sistemi (GNSS) gibi uydu konumlandırma teknolojilerindeki hızlı gelişmelerle birlikte koordinat konumları yüksek doğrulukla elde etme olasılığını artırmıştır. Bu konumlandırma teknolojileri, noktanın konumlarını elipsoidal jeodezik koordinat ( $\phi$ ,  $\lambda$ ,  $h$ ) olarak ya da üç boyutlu (3B) global kartezyen koordinat (X, Y, Z) olarak sunmaktadır. GNSS'in doğru kullanımı için ülke sistemiyle arasındaki ilişkilerin tanımlanması gerekir. Her iki sistemin jeodezik alt yapısı farklıdır. GNSS ile elde edilen koordinat bilgisinin ülke sisteminde kullanılabilmesi için, üç boyutlu (3B) global kartezyen koordinat ve elipsoidal jeodezik koordinat sistemleri arasında dönüşüm yapılması gereklidir (Yıldırım vd., 2011). Üç boyutlu global kartezyen koordinatlardan elipsoidal jeodezik koordinatlara dönüşüm hesabı için farklı yöntemler geliştirilmişken, tersi işlem için tek bir çözüm mevcuttur.

Farklı mühendislik disiplinlerinde kullanılan yapay sinir ağının (YSA) jeodezi alanında da klasik koordinat yöntemlere alternatif olabileceği yapılan birçok çalışma ile kanıtlanmıştır. Bazı araştırmacılar YSA'larını iki boyutlu (2B) ve üç boyutlu (3B) koordinat dönüşüm metodu olarak kullanmışlardır (Zaletnyik, 2004; Lin ve Wang, 2006; Tierra vd., 2008; Gullu, 2010; Tierra ve Romero, 2014; Konakoğlu ve Gökalp, 2016; Elshambaky vd., 2018; Cakir ve Konakoglu, 2019; Ziggah vd., 2019). Bu çalışmalara örnek olarak, Turgut, B. (2010) yaptığı çalışmada çok katmanlı yapay sinir ağı (ÇKAYSA) kullanarak ED50 (European Datum 1950) ve WGS84 (World Geodetic System 1984) datumları arası 3B global kartezyen koordinatların dönüşümünde kullanmıştır. ÇKAYSA sonuçları, 7-parametrelilik benzerlik dönüşüm yöntemi (Molodensky-Badekas) sonuçları ile karşılaştırılmıştır. Yapılan test sonuçlarına göre, ÇKAYSA'nın Molodensky-Badekas yönteminden daha doğru sonuç verdiği, ÇKAYSA'nın ED50 ve WGS84 datumları arası 3B koordinat dönüşümünde kullanılabileceği sonucuna varılmıştır. Konakoglu vd. (2016) yaptıkları çalışmada üç farklı yapay sinir ağı modelinin (ileri beslemeli geriye yayılım yapay sinir ağı (İBGYYSA), ileri kademeli geri yayılım yapay sinir ağı (İKGYYSA) ve radyal temelli fonksiyon yapay sinir ağı (RTFYSA)) ED50 ve ITRF (International Terrestrial Reference Frame)

datumlarında bulunan 2B'lu koordinat dönüşümü performansını incelemişlerdir. Sonuçlar, optimum model parametrelerinin seçildiği durumlarda YSA'larının 2B koordinat dönüşümü için kullanılabileceğini göstermiştir. Ziggah vd. (2016a) yaptıkları çalışmada Gana'da kullanılan 2B'lu iki farklı bölgesel datum arasında dönüşüm için YSA'nı kullanmışlardır. ÇKAYSA ve RTFYSA yöntemleri iki farklı klasik dönüşüm yöntemleri (4- ve 6- parametrelilik modeller) ile karşılaştırılmıştır. Sonuçlar, bir datumdan diğerine, RTFYSA'nın, ÇKAYSA ve diğer iki klasik dönüşüm yöntemlerinden daha iyi olduğunu göstermiştir. Bu nedenle, bu çalışma Gana'nın koordinat dönüşüm problemlerini çözmeye YSA tekniğinin önemini anlamada fırsat yaratmıştır. Elshambaky vd. (2018) yaptıkları çalışmada Mısır datumunun koordinatlarını dönüşümünde YSA yöntemini yeni bir datum dönüşüm aracı olarak kullanılmasını göstermişlerdir. Klasik yöntemlerden Helmert ve Molodensky, regresyon ve minimum eğrilik yüzeyi yöntemleri kullanılarak elde edilen sonuçlar YSA ile yapılan sonuçlar ile karşılaştırılmıştır. Yapılan karşılaştırma sonucunda YSA yönteminin, Mısır'daki dönüşüm problemini çözmek için bir araç olarak kullanılmasında diğer yöntemlere göre daha uygun bir yöntem olduğunu tespit etmişlerdir. Ziggah vd. (2016b) yaptıkları çalışmada jeodezik elipsoidal koordinatların ( $\phi$ ,  $\lambda$ ,  $h$ ) 3B kartezyen koordinatlara (X, Y, Z) dönüştürülmesinde YSA'nın kullanımını araştırmışlardır. Yapılan çalışma kapsamında, YSA olarak ÇKAYSA, radyal temelli fonksiyon sinir ağı (RTFYSA) ve çoklu lineer regresyon (ÇLR) modelleri kullanılmıştır. Veri olarak batı Afrika'da bulunan Gana, Tarkwa'da arazi ölçümü ile toplanan toplam 328 GPS koordinat verisi kullanılmıştır. Girdi verisi olarak enlem ( $\phi$ ), boylam ( $\lambda$ ), yükseklik ( $h$ ), ana eğrilik yarıçapı (N) ve birinci merkezdeşliliğin karesi ( $e^2$ ) kullanılmıştır. Çıktı verisi olarak her bir 3B global kartezyen koordinatların bileşenleri (X, Y, Z) ayrı ayrı kullanılmıştır. Modellemede gizli katman sayısı 1 olarak alınmıştır. Her bir bileşen için oluşturulan modeller, Levenberg-Marquardt eğitim algoritması ile eğitilmiştir. ÇKAYSA, RTFYSA ve ÇLR modelleri arasındaki yapılan karşılaştırmada, RTFYSA'nın ÇKAYSA ve ÇLR'dan çok daha iyi sonuçlar üretmiştir.


Bu çalışma kapsamında ise toplam 594 adet Türkiye Ulusal Temel GPS Ağı'na (TUTGA) ait nokta veri seti kullanılarak, jeodezik elipsoidal koordinatların global kartezyen koordinatlara dönüşümünde YSA'nın kullanımının test edilmesi amaçlanmıştır. Dönüşüm işlemi YSA'nın en çok

kullanılan modeli olan çok katmanlı algılayıcı yapay sinir ağı (ÇKAYSA) kullanılarak gerçekleştirilmiştir. Çalışma kapsamında ÇKAYSA'nın seçilme nedeni bu modelin jeodezik uygulamalarda yüksek performansla çalışmasıdır. Ziggah vd. (2016b) yaptıkları çalışmasından farklı olarak girdi verisi olarak enlem ( $\varphi$ ), boylam ( $\lambda$ ) ve yükseklik ( $h$ ) kullanılırken, çıktı verisi olarak her bir 3B global kartezyen koordinatların bileşenleri ( $X$ ,  $Y$ ,  $Z$ ) ayrı ayrı kullanılmıştır. ÇKAYSA ile oluşturulan modellerin performansı, karesel ortalama hata (KOH), ortalama mutlak hata (OMH) ve belirlilik katsayısı ( $R^2$ ) değerleri dikkate alınarak belirlenmiştir.

## 2. Yöntemler

### 2.1. Klasik Yaklaşım

Bir noktanın üç boyutlu (3B) global kartezyen koordinatlarıyla ( $X$ ,  $Y$ ,  $Z$ ) jeodezik elipsoidal koordinatların ( $\varphi$ ,  $\lambda$ ,  $h$ ) arasındaki ilişki;



Şekil 1. 3B global kartezyen ve jeodezik elipsoidal koordinatlar (Üstün, 1996)

Üç boyutlu (3B) global kartezyen koordinatlar ( $X$ ,  $Y$ ,  $Z$ ) ve jeodezik elipsoidal koordinatların ( $\varphi$ ,  $\lambda$ ,  $h$ ) birbirleriyle olan dönüşümünü sağlayan denklemler (1) – (3) olarak ifade edilebilir (Heiskanen ve Moritz, 1967):

$$X = (N + h) \cos \varphi \cos \lambda \quad (1)$$

$$Y = (N + h) \cos \varphi \sin \lambda \quad (2)$$

$$Z = [N(1 - e^2) + h] \sin \varphi \quad (3)$$


$$N = \frac{a}{\sqrt{1 - e^2 \sin^2 \varphi}} \quad (4)$$

$$e = \frac{\sqrt{a^2 - b^2}}{a} \quad (5)$$

Burada  $\varphi$ , ( $-\pi/2 \leq \varphi \leq +\pi/2$ ) jeodezik enlemi;  $\lambda$  ( $-\pi < \lambda \leq +\pi$ ) jeodezik boylamı;  $h$  ( $-b \leq h < +\infty$ ) jeodezik yüksekliği;  $e$ , birinci merkez dışılığı;  $a$ , jeodezik elipsoidin büyük yarı eksenini;  $b$ , jeodezik elipsoidin küçük yarı eksenini ifade etmektedir.

### 2.2. Çok Katmanlı Algılayıcı Yapay Sinir Ağı (ÇKAYSA)

Yapay sinir ağları (YSA), en güçlü ve esnek makine öğrenme yöntemleri olarak bilinir. YSA'ları insan beyninin çalışma sisteminden esinlenerek geliştirilmiştir. YSA'nın yaygın kullanımının en önemli nedeni, klasik yöntemlerle çözümü zor problemler için etkin bir alternatif oluşturmasıdır. Çok katmanlı algılayıcı yapay sinir ağı (ÇKAYSA), basit bir yapıya sahip en yaygın olarak kullanılan ve geleneksel ileri beslemeli YSA'ları arasında popüler olan bir modeldir. Tek katmanlı algılayıcılar doğrusal olayları tahmin edebilirken, ÇKAYSA doğrusal olmayan olayların tahmininde kullanılabilir (Haykin, 2009). ÇKAYSA, bir giriş katmanı, bir veya daha fazla gizli katman(lar) ve bir çıkış katmanı dâhil olmak üzere birkaç katmandan oluşmaktadır. ÇKAYSA'nda, giriş katmanı girdi parametrelerinin girdiği yerdir. Çıktı katmanı parametrelerine ilişkin değerler, ilgilenilen problemin hedef değerlerine göre belirlenir. Şekil 2, ÇKAYSA'nın mimarisine bir örnek göstermektedir.



Şekil 2. Çok katmanlı algılayıcı yapay sinir ağı mimarisine

Şekil 1'den de görüldüğü gibi katman içerisinde bulunan nöronların kendi aralarında bir bağlantı yoktur (Kisi ve Alizamir, 2018). Her bir katmandaki veriler, bir önceki ve bir sonraki katmanlardaki diğer nöronlarla birbirine bağlanan nöronlar aracılığı ile aktarılır. Bağlantılar sinaptik ağırlıklar ve hatalar ile ilişkilidir ve ağırlıkların amacı bu parametreleri sistemin eğitimi yoluyla ayarlamaktır (Kisi vd., 2017). Gizli katmanda yer alacak nöron sayısı uygulamaya göre değişmekte olup genellikle deneme yanılma yoluyla tespit edilmektedir. Girdi ve çıktı nöronlarının değerlerinin ayarlanmasından sonraki adım, ağırlıkların her nöronun aktif fonksiyonuna uygun olarak gizli nöronlarla ilişkili parametreleri tahsis etmesi için eğitilmesidir. Girdi vektörünün  $x_i$  olduğu düşünüldüğünde, bir transfer fonksiyonundan geçirilerek işlem elemanının çıktı değeri aşağıdaki eşitlik ile elde edilir.

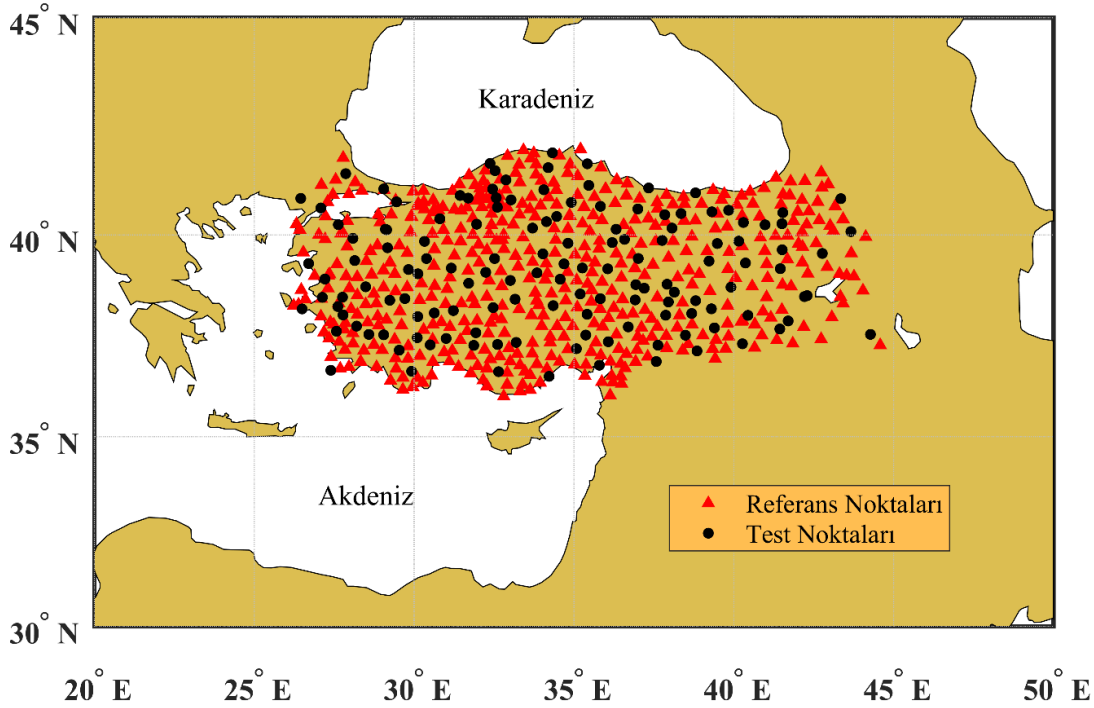
$$y_i = f\left(\sum_{i=1}^n w_{ji}x_i + b\right) \quad (6)$$

Burada  $f$ , aktivasyon fonksiyonunu;  $n$ , girdi sayısını;  $w_{ji}$ ,  $i$ . işlem elemanından  $j$ . işlem

elemanına olan ağırlık değerini;  $b$ , eşik değerini göstermektedir. Aktivasyon fonksiyonu doğrusal ve doğrusal olmayan fonksiyonlar şeklinde ikiye ayrılır. Doğrusal olmayan fonksiyonlarda en çok kullanılanı sigmoid ve hiperbolik tanjant fonksiyonlarıdır. Bu çalışmada, aktivasyon fonksiyonu olarak hiperbolik tanjant fonksiyonu kullanılmıştır.

### 3. Veri Seti

Çalışma kapsamında, toplam 594 adet TUTGA noktasından oluşturulan veri seti uygulamada, referans ve test olarak iki ayrı veri setine ayrılarak kullanılmıştır. Nokta verilerinin dağılımlarının homojen bir şekilde dağılmış olmasına dikkat edilmiştir. Tüm veri setinin yaklaşık %80'i (475 nokta) ÇKAYSA'nın eğitiminde kullanılırken, geri kalan %20'si (119 nokta) ÇKAYSA modellerinin performansının değerlendirilmesinde kullanılmıştır. Referans ve test veri setine ait jeodezik noktaların dağılımı Şekil 3'te gösterilmiştir.



Şekil 3. Referans ve test noktalarının dağılımı

Girdi ve çıktı verileri, hesaplama hızını iyileştirmek ve daha doğru sonuçlar elde etmek için YSA modellerini geliştirmeden önce bir ölçeklendirme kriterine göre normalleştirilmelidir. Bu çalışmada kullanılan enlem ( $\phi$ ), boylam ( $\lambda$ ) ve yükseklik ( $h$ ), 3B global kartezyen koordinatların bileşenleri ( $X, Y, Z$ ) eşitlik (7) kullanılarak -1 ile 1 arasında normalleştirilmiştir.

$$x_i = x_{min} + \frac{(x_{mak}-x_{min}) \times (y_i - y_{min})}{(y_{mak}-y_{min})} \quad (7)$$

Burada  $x_i$ , normalize veriyi;  $y_i$ , normalleştirilmemiş veriyi;  $y_{min}$  ve  $y_{mak}$  normalleştirilmemiş verinin minimum ve maksimum değerlerini;  $x_{min}$  ve  $x_{mak}$  -1 ve 1 değerlerini göstermektedir.

#### 4. Modelin Performans Değerlendirmesi

Bu çalışmada geliştirilen ÇKAYSA modellerinin performansını değerlendirmek için üç değerlendirme ölçütü, karesel ortalama hata (KOH), ortalama mutlak hata (OMH) ve belirlilik

katsayısı ( $R^2$ ) kullanılmıştır. Bu ölçütler şu şekilde tanımlanır:

$$KOH = \left( \frac{1}{n} \sum_{i=1}^n (H_i - T_i)^2 \right)^{1/2} \quad (8)$$

$$OMH = \frac{1}{n} \sum_{i=1}^n |H_i - T_i| \quad (9)$$

$$R^2 = \left( \frac{\sum_{i=1}^n (H_i - \bar{H})(T_i - \bar{T})}{\sqrt{\sum_{i=1}^n (H_i - \bar{H})^2 \sum_{i=1}^n (T_i - \bar{T})^2}} \right)^2 \quad (10)$$

Burada  $n$ , veri sayısını;  $H_i$  ve  $T_i$ , sırasıyla hesaplanan ve tahmin edilen değerleri;  $\bar{H}$  ve  $\bar{T}$ , sırasıyla ortama hesaplanan ve ortalama tahmin edilen değeri göstermektedir.

#### 5. Uygulama

Jeodezik elipsoidal koordinatların ( $\varphi$ ,  $\lambda$ ,  $h$ ), 3B global kartezyen koordinatlara ( $X$ ,  $Y$ ,  $Z$ ) ÇKAYSA ile dönüşümünde referans ve test noktalarının coğrafi koordinatları ( $\varphi$ ,  $\lambda$ ,  $h$ ) girdi verisi olarak ve noktanın her bir global kartezyen koordinat bileşeni çıktı verisi olarak kullanılmıştır. Gizli katman sayısının seçimi YSA'nın işleyişinde önemli bir adımdır ve bunun için kesin bir yöntem bulunmamaktadır. Tek bir gizli katmanın kullanımının yeterli olduğu [Hornik vd. \(1989\)](#) tarafından belirtilmiştir. Buna rağmen, 1 gizli katmana sahip ÇKAYSA'nın eğitim aşamasında yapılan denemeler sonucunda karesel ortalama hata (KOH) değerinin metre seviyesinde kaldığı tespit edilmiştir. Bir katman kullanılarak elde edilen sonuçlara bu makalede yer verilmemiştir. Bu yüzden, ÇKAYSA modellerinde 2 gizli katman kullanılmıştır. Eğitim aşamasından önce, sorun için en uygun eğitim algoritması seçilmelidir. Yapılan denemeler sonucunda ÇKAYSA'nın eğitimi için, *Bayesian Regulation* eğitim algoritmasının kullanılmasının uygun olduğu belirlenmiştir. *Bayesian Regulation* eğitim algoritması için daha fazla bilgiye [MacKay \(1992\)](#) çalışmasından ulaşılabilir. Geçmişte, gizli katmandaki nöron sayısının hesaplanması için birçok yaklaşım önerilmiştir. Fakat bu çalışmada, gizli nöronların sayısı deneme yanılma yaklaşımı ile saptanmıştır.

Optimum nöron sayısını seçmek için KOH ölçüt olarak alınmıştır. Beş gizli nöron dan başlayarak, gerekli doğruluk elde edilene kadar gizli nöronların sayısı her denemede 5'er kez artırılmıştır. Nöronlarda aktivasyon fonksiyonu olarak hiperbolik tanjant fonksiyonu kullanılmıştır. Her bir global kartezyen koordinat bileşeni için oluşturulan ÇKAYSA modellerinde öğrenme oranı 0.4, momentum değeri ise 0.5 olarak seçilmiştir. Öğrenme oranı, bir öğrenme prosedürünün hızı ve doğruluğu ile orantılı olup bunları kontrol eden bir sabittir. Momentum katsayısı, ağın yerel gradientleri aşmasını sağladığı gibi aynı zamanda hatanın düşmesine de yardımcı olur. Bu katsayı ile öğrenme esnasında ağın salınımını engellenir. Birçok denemeden sonra, jeodezik elipsoidal koordinatların 3B global kartezyen koordinatlara dönüştürmek için ÇKAYSA'nın optimum yapısı  $X$ ,  $Y$  ve  $Z$  bileşenleri için sırasıyla [3-5-5-1], [3-10-10-1] ve [3-10-10-1] olarak belirlenmiştir.

##### 5.1. Eğitim Aşaması Sonuçları


ÇKAYSA modellerinin KOH, OMH ve  $R^2$  açısından eğitim aşaması için performansı Tablo 1'de verilmiştir.

Sonuçlara göre,  $X$ ,  $Y$  ve  $Z$  bileşenleri için geliştirilen ÇKAYSA modellerindeki eğitim verilerine ait elde edilen KOH ve OMH değerleri, hesaplanan global kartezyen koordinat değerlerinin eğitim sonucu elde edilen koordinat değerlerine oldukça yakın olduğunu göstermektedir. Bu durum grafiksel olarak Şekil 4'te gösterilmiştir.

**Tablo 1.** ÇKAYSA modellerinin için eğitim aşaması sonuçları

Aşama	Ölçüt	X	Y	Z
Eğitim	KOH (cm)	1.0963	0.8822	0.5004
	OMH (cm)	0.3768	0.2511	0.1455
	$R^2$	0.9999	0.9999	0.9999






Şekil 4. Eğitim veri için tahmin ve bilinen koordinat değerlerinin dağılım diyagramları

Ayrıca, eğitim aşamasında elde edilen yüksek  $R^2$  değeri (Tablo 1), her bir global kartezyen koordinat bileşeni için geliştirilen modellerin eğitim performanslarının kalitesini daha da doğrulamıştır. Tüm bu sonuçlardan yola çıkarak, düşük KOH ve OMH ve yüksek  $R^2$  değeri ile tatmin edici bir eğitim performansı sergilemiş olduğu göstermektedir.

ÇKAYSA modelleri ile tahmin edilen koordinat değerlerinin yakınlığına bağlı olarak, tahmin edilen sonuçların karşılık gelen hesaplanan koordinatlardan sapma miktarını Şekil 4 yardımıyla görsel olarak tanımlamak güçtür. Bu nedenle, eğitim aşamasında ÇKAYSA modellerinden elde edilen koordinat farklarını açıkça gösteren bir grafiğin gösterilmesi önemlidir. Farklar, tahmin edilen koordinatlara karşılık gelen hesaplanan koordinatlarından

çıkararak hesaplanmıştır. Elde edilen bu farklar ile geliştirilen ÇKAYSA'nın tahmin limitini göstermektedir. Şekil 5 tüm bileşenler için geliştirilen modelleri kullanıldığında, eğitim veri noktalarına göre fark değişimlerini göstermektedir.

Klasik yöntemle hesaplanan koordinatlar ile tahmin edilen koordinatların farklarının sıfır olması beklenir; fakat bu durum mümkün değildir. Bu grafik gösterimleri ile ÇKAYSA modelleri kullanılarak tahmin edilen koordinat değerlerinin, hesaplanan koordinat değerleri ile ne kadar uyumlu olduğunu daha açık gösterebilmektedir. Şekil 5 incelendiğinde fark değerlerinin az sayıda veri hariç sıfır değerine oldukça yakın olduğu görülmektedir. Bu durumdan yola çıkacak olursak kurulan modelin iyi bir şekilde eğitilmiş olduğu sonucuna varılmıştır.



Şekil 5. Eğitim verileri için hesaplanan fark değerleri


## 5.2. Test Aşaması Sonuçları

Eğitim aşaması bitmesinden sonra oluşturulan ÇKAYSA modellerinin performanslarını değerlendirmek için test aşamasına geçilmiştir. Test aşaması için bulunan istatistiksel sonuçlar Tablo 2’de verilmiştir.

KOH ve OMH sonuçlara göre, geliştirilen modellere girdi olarak verilen test verilerinin koordinat değer sonuçları, hesaplanan koordinat verileri ile önemli ölçüde yakın olduğu sonucuna varılmıştır. Bu durum, ÇKAYSA’nın iyi şekilde geliştirildiğini göstermektedir. Test aşaması için hesaplanan ve tahmin edilen koordinatların grafiksel gösterimi Şekil 6’da verilmiştir.

**Tablo 2.** ÇKAYSA modellerinin için test aşaması sonuçları

Aşama	Ölçüt	X	Y	Z
Test	KOH (cm)	0.9411	0.8420	0.4536
	OMH (cm)	0.8165	0.6102	0.3883
	R <sup>2</sup>	0.9999	0.9999	0.9999




**Şekil 6.** Test veri için tahmin ve hesaplanan koordinat değerlerinin dağılım diyagramları

Ayrıca test verilerine dayalı ÇKAYSA tahminlerinin yeterliliği R<sup>2</sup> ölçütü kullanılarak da tespit edilmiştir. R<sup>2</sup> sonuçlarına göre, geliştirilen tüm ÇKAYSA modellerinde 1’e yakın değerler verdiği açıktır. Bu durum, test verilerinin kullanılarak yapılan tahmin sonucu elde edilen koordinatların hesaplanan koordinatları ile oldukça yakın olduğunu göstermektedir. Test aşaması için düşük KOH ve OMH ve yüksek R<sup>2</sup> değerinin elde edilmesi ÇKAYSA’nın jeodezik elipsoidal koordinatların 3B global kartezyen koordinatlara dönüşümünde kullanılabileceğini göstermiştir.

Test aşamasında da koordinat farkları, tahmin edilen koordinatlara karşılık gelen hesaplanan koordinatlarından çıkararak hesaplanmıştır. Şekil 7 tüm bileşenler için geliştirilen modelleri kullanıldığında, test veri noktalarına göre fark değişimlerini göstermektedir.

Şekil 7 incelendiğinde fark değerlerinin az sayıda veri hariç sıfır değerine oldukça yakın olduğu görülmektedir. Bu durumdan yola çıkacak olursak kurulan modelin test sonuçlarının da yeterli hassasiyete sahip olduğu sonucuna varılmıştır.



Şekil 7. Test verileri için hesaplanan fark değerleri

## 6. Sonuçlar ve Öneriler

Jeodezik elipsoidal koordinatlardan ( $\phi$ ,  $\lambda$ ,  $h$ ) 3B global kartezyen koordinatlara (X, Y, Z) dönüşüm işlemi jeodezide oldukça yaygın bir şekilde kullanılmaktadır. Bu dönüşüm işlemi matematiksel olarak tek bir yöntem ile yapılmaktadır. Yapılan bu çalışmanın amacı, çok katmanlı algılayıcı yapay sinir ağı (ÇKAYSA)'nın bilinen klasik dönüşüm yöntemine alternatif olarak kullanılabilirliğini araştırmaktır. Dönüşüm işlemi için, 594 noktalı TUTGA koordinat verisi kullanılmıştır. Bu kapsamda, oluşturulan ÇKAYSA'nda girdi verisi olarak jeodezik elipsoidal koordinatlar ( $\phi$ ,  $\lambda$ ,  $h$ ), çıktı verisi olarak her bir 3B global kartezyen koordinatı (X, Y, Z) YSA modeline tanıtılmıştır. Her bir bileşen için uygun ÇKAYSA modeli bulunmuştur. Daha önce Ziggah vd. (2016b) girdi verisi olarak enlem ( $\phi$ ), boylam ( $\lambda$ ), yükseklik ( $h$ ), ana eğrilik yarıçapı (N) ve birinci merkez dışılığı karesi ( $e^2$ ) kullanılarak modelleme yapmışlardır. Levenberg-Marquardt eğitim algoritması kullanarak yaptıkları çalışmada bir gizli katman yeterli hassasiyete ulaşılmıştır. Bu çalışmada ise Bayesian Regulation eğitim algoritması kullanılarak oluşturulan iki gizli katmanlı dönüşüm modelleri yeterli derecede sonuç vermiştir. Yapılan çok sayıda deneme sonucunda, en düşük KOH, OMH ve en büyük  $R^2$  değerlerine bakılarak modellerin X, Y ve Z bileşenleri için sırasıyla [3-5-5-1], [3-10-10-1] ve [3-10-10-1] mimarisine sahip ÇKAYSA modeli olduğu görülmüş ve bu modeller yardımıyla jeodezik elipsoidal koordinatlardan 3B global kartezyen koordinatlara dönüşüm hesabı

gerçekleştirilmiştir. Test sonuçları incelendiğinde tüm bileşenler için KOH ve OMH hataların 1 cm'nin altında kaldığı belirlenmiştir. Ayrıca, tüm bileşenler için  $R^2$  değeri 1'e çok yakın çıkmıştır. İstatistiksel kriterlere ek olarak tahmin ile hesaplanan koordinat değerleri arasındaki farklara göre çoğu farkın sifira yakın olduğu tespit edilmiştir. Tüm sonuçlara göre ÇKAYSA'nın jeodezik elipsoidal koordinatlardan ( $\phi$ ,  $\lambda$ ,  $h$ ) 3B global kartezyen koordinatlara (X, Y, Z) dönüşüm işlemi için alternatif bir yöntem olarak kullanılabilirliği çıkarımı yapılabilir. Ziggah vd. (2016) ve bu çalışma arasındaki fark veri setine veya farklı girdi verisinin kullanımı olabilir. Aynı veri seti ile radyal temelli fonksiyon yapay sinir ağı (RTFYSA) ve genelleştirilmiş regresyon yapay sinir ağı (GRYSA) gibi farklı YSA modelleri de kullanılıp, ÇKAYSA ile performans karşılaştırması yapılabilir. Bu çalışmanın jeodezide yapılan YSA uygulamalarına ek bir katkı sağlayacağı düşünülmektedir.

## Teşekkür

Yazar, makalenin son şeklini almasındaki değerli katkıları için üç hakeme teşekkür eder.

## Kaynaklar

Cakir, L. ve Konakoglu, B., 2019. The Impact of Data Normalization on 2D Coordinate Transformation Using GRNN. Geodetski Vestnik, 63(4), 541-553. doi: 10.15292/geodetski-vestnik.2019.04.541-553.



- Elshambaky, H.T., Kaloop, M.R. ve Hu, J.W., 2018. A Novel Three-direction Datum Transformation of Geodetic Coordinates for Egypt Using Artificial Neural Network Approach. *Arabian Journal of Geosciences*, 11(6), 110. doi: 10.1007/s12517-018-3441-6.
- Gullu, M., 2010. Coordinate Transformation by Radial Basis Function Neural Network. *Scientific Research and Essays*, 5, 3141-3146.
- Haykin, S., 2009. *Neural Networks and Learning Machines*. NJ: Pearson Education Inc.
- Heiskanen, W.A. ve Moritz, H., 1967. *Physical geodesy*: San Fransisco, USA, W.H. Freeman and Company, 364p.
- Hornik, K., Stinchcombe, M. ve White, H., 1989. Multilayer Feedforward Networks Are Universal Approximators. *Neural Networks*, 2(5), 359-366. doi: 10.1016/0893-6080(89)90020-8.
- Kisi, O. ve Alizamir, M., 2018. Modelling Reference Evapotranspiration Using a New Wavelet Conjunction Heuristic Method: Wavelet Extreme Learning Machine vs Wavelet Neural Networks. *Agricultural and Forest Meteorology* 263: 41-48. doi: 10.1016/j.agrformet.2018.08.007.
- Kisi, O., Alizamir, M. ve Zounemat-Kermani, M., 2017. Modeling Groundwater Fluctuations by Three Different Evolutionary Neural Network Techniques Using Hydroclimatic Data. *Natural Hazards*, 87(1), 367-381. doi: 10.1007/s11069-017-2767-9.
- Konakoglu, B., Cakır, L. ve Gökalp, E., 2016. 2D Coordinate Transformation Using Artificial Neural Networks. *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*. 42, 183-186. doi: 10.5194/isprs-archives-XLII-2-W1-183-2016.
- Konakoğlu, B. ve Gökalp, E., 2016. A Study on 2D Similarity Transformation Using Multilayer Perceptron Neural Networks and a Performance Comparison with Conventional and Robust Outlier Detection Methods. *Acta Montanistica Slovaca*, 21(4), 324-332.
- Lin, L.S. ve Wang, Y.J., 2006. A Study on Cadastral Coordinate Transformation Using Artificial Neural Network, 27<sup>th</sup> Asian conference on remote sensing, Ekim 2006, Ulaanbaatar, Mongolia.
- MacKay, D.J., 1992. Bayesian Interpolation. *Neural computation*, 4(3), 415-447.
- Tierra, A. ve Romero, R., 2014. Planes Coordinates Transformation Between PSAD56 to SIRGAS Using a Multilayer Artificial Neural Network. *Geodesy and Cartography*, 63(2), 199-209. doi: 10.2478/geocart-2014-0014.
- Tierra, A., Dalazoana, R. ve De Freitas, S., 2008. Using An Artificial Neural Network to Improve The Transformation of Coordinates Between Classical Geodetic Reference Frames. *Computers and Geosciences*, 34(3), 181-189. doi: 10.1016/j.cageo.2007.03.011.
- Turgut, B., 2010. A Back-propagation Artificial Neural Network Approach for Three Dimensional Coordinate Transformation. *Scientific Research and Essays*, 5(21), 3330-3335.
- Üstün, A., 1996. *Datum Dönüşümleri, Yüksek Lisans Tezi, Yıldız Teknik Üniversitesi Fen Bilimleri Enstitüsü. İstanbul*, 85s.
- Yıldırım, F., Kaya, A. ve Kaplan, Y., 2011. Jeodezik Dik ve Coğrafi Koordinat Dönüşüm Yöntemlerinin Karşılaştırılması. *Harita Dergisi*, 146, 1-7.
- Zaletnyik, P., 2004. Coordinate Transformation with Neural Networks and with Polynomials in Hungary, *International symposium on modern technologies, education and professional practice in geodesy and related fields*, Sofia, Bulgaria, s.471-479.
- Ziggah, Y.Y., Youjian, H., Tierra, A.R. ve Laari, P.B., 2019. Coordinate Transformation Between Global and Local Data Based on Artificial Neural Network with K-Fold Cross-Validation in Ghana. *Earth Sciences Research Journal*, 23(1), 67-77. doi: 10.15446/esrj.v23n1.63860.
- Ziggah, Y.Y., Youjian, H., Tierra, A., Konaté, A.A. ve Hui, Z., 2016a. Performance Evaluation of Artificial Neural Networks for Planimetric Coordinate Transformation—a Case Study, Ghana. *Arabian Journal of Geosciences*, 9(17), 698. doi: 10.1007/s12517-016-2729-7.
- Ziggah, Y.Y., Youjian, H., Yu, X. ve Basommi, L.P., 2016b. Capability of Artificial Neural Network for Forward Conversion of Geodetic Coordinates ( $\phi$ ,  $\lambda$ ,  $h$ ) to Cartesian Coordinates ( $X$ ,  $Y$ ,  $Z$ ). *Mathematical Geosciences*, 48(6), 687-721. doi: 10.1007/s11004-016-9638-x.