

Yapay Sinir Ağları Yardımıyla Yükseklik Modellemesi (Samsun-Mert Irmağı Havzası Örneği)

Vahdettin DEMİR^{*,a}, Aslı ÜLKE KESKİN^b

^{a,*} KTO Karatay Üniversitesi İnşaat Mühendisliği Bölümü, ORCID: 0000-0002-6590-5658, 42020, KONYA, TÜRKİYE

^b Ondokuzmayıs Üniversitesi İnşaat Mühendisliği Bölümü, ORCID: 0000-0002-9676-8377, 55270, SAMSUN, TÜRKİYE

MAKALE BİLGİSİ

Alınma: 14.11.2019
Kabul: 28.04.2020

Anahtar Kelimeler:

Yükseklik Modeli,
Yapay Sinir Ağları,
Tahmin, Samsun

***Sorumlu Yazar:**

e-posta:
vahdettin.demir@karatay.edu.tr

ÖZET

Birçok mühendislik uygulamasında, topoğrafik yüzeye ihtiyaç duyulmakta ve topoğrafyanın uygun doğrulukta belirlenmesi gerekmektedir. Sayısal yükseklik modeline dayalı uygulamalarda olduğu gibi, örnek çalışma alanı yatay ve düşey konum bilgileri kullanılarak yükseklik değerleri uygun yöntemlerle belirlenebilir. Bu çalışmada Samsun ili Mert ırmağı havzası ve kent sınırlarının kesiştiği alanda, hâlihazır haritalardan temin edilmiş yatay ve düşey koordinat bilgilerinin yer aldığı noktalardan, yükseklik (kot) değerleri yapay sinir ağları yöntemlerinden Çok Katmanlı Yapay Sinir Ağları (ÇKYSA) ve regresyon analizi kullanılarak tahmin edilmeye çalışılmıştır. Çalışmada 3 farklı kombinezon denenmiştir. Bunlar: (i) X koordinat bilgisiyle yükseklik tahmini; (ii) Y koordinat bilgisiyle yükseklik tahmini; (iii) X ve Y koordinat bilgisiyle yükseklik tahmini şeklindedir. Karşılaştırma kriterleri olarak Karekök Ortalama Karesel Hata (KOKH), Ortalama Mutlak Hata (OMH) ve determinasyon katsayısı (R^2) kullanılmıştır. OMH, KOKH ve R^2 kriterlerine göre yükseklik modellemesinde yapay sinir ağı modelinin regresyon modellerinden daha iyi uyum (uygun doğruya) sağladığı gözlenmiştir. En yüksek R^2 değeri (0.948) (iii) kombinezonunun giriş verisi olarak kullanıldığı ÇKYSA modelinden elde edilmiştir. En düşük R^2 değeri ise 0.132 (ii) kombinezonunun denendiği regresyon modelinde görülmüştür. Yapılan modelleme sonucunda yükseklikler (iii) kombinezonu ve ÇKYSA ile daha başarılı tahmin edilmiştir. Dolayısıyla, yapay sinir ağlarının regresyon analizine alternatif bir yöntem olabileceği sonucuna ulaşılmıştır.

<https://dx.doi.org/10.30855/gmbd.2020.01.05>

Height Modeling with Artificial Neural Networks (Samsun-Mert River Basin)

ARTICLE INFO

Received: 14.11.2019
Accepted: 28.04.2020

Keywords:

Elevation Models,
Artificial Neural
Network, Prediction,
Samsun

***Corresponding**

Authors

e-mail:
vahdettin.demir@karatay.edu.tr

ABSTRACT

In many engineering applications, it is needed topographical and surface topography is required to determine the appropriate accuracy. As applications based on digital elevation model case study of height values using horizontal and vertical position information may be determined by appropriate methods. In this study, Samsun Mert river basin and at the intersection of the city limits, the present progress has been providing horizontal and vertical elevation values of the point where the coordinates of the map information have been studied to predict. Multi-Layer Artificial Neural Networks (MLANN), and regression analysis were used. The study was tested in three different combinations. These include: (i) X coordinate of the estimated height information; (ii) the estimated height of the Y coordinate information; (iii) the estimated height information in the form of X and Y coordinates. As a comparison criterion Root Mean Square Error (RMSE), Mean Absolute Error (MAE) and the determination coefficients (R^2) were used. When the models were compared, Artificial Neural Networks (ANN) model gave a better fit (fit-line) than Multiple Linear Regression (MLR) and linear regression (LR) models. The highest R^2 value (0.948) was found from the ANN model where the combination (iii) was used as input data. The lowest R^2 value (0.132) was obtained from the regression model where the combination (ii) was used as input data. As a result of modeling, heights have been estimated more successfully with the (iii) combination of ANN. Therefore, ANN was determined as an alternative method to regression analysis.

1. INTRODUCTION (GİRİŞ)

Hidrografik amaçlı birçok Mühendislik uygulamasında, topoğrafik yüzeye ihtiyaç duyulmakta ve topografyanın uygun doğrulukta belirlenmesi gerekmektedir. Bu amaçla sayısal yükseklik modeline dayalı uygulamalarda olduğu gibi, örnek çalışma alanı yatay ve düşey konum bilgileri kullanılarak yükseklik değerleri uygun yöntemlerle belirlenebilir. İster arazi üzerinden alım, isterse uzaktan algılama yöntemlerine göre olsun yükseklik bilgisinin belirlenmesi haritacılıkta her zaman güç bir konu olmuştur. Bu güçlük bilinen fonksiyonların dışında kapalı kutu modellere dayalı yapay sinir ağlarının modellenebilirliği ile aşılabılır.

Yapay Sinir Ağları (YSA), insan beyninin deneme yanılma yoluyla öğrenme ve öğrendiğini genelleştirme esasına dayanan bir sistemdir. Birçok mekanizma ve sistemin çıktılarını hesaplamak için yaygın olarak kullanılan yöntemlerden biridir. Birçok akademisyen tarafından değişik disiplinlerde (finans, sağlık, mühendislik, fizik, jeoloji ve hidroloji alanlarında) başarılı bir şekilde kullanılmaktadır [1–14]. YSA ile ilgili literatürde birçok çalışma olmasına rağmen konum bilgilerine dayalı YSA kullanımıyla ilgili çalışmalar oldukça kısıtlıdır. Çalışmalar, genellikle polinomal ve radyal tabanlı yüzey modellemesi [15], iki boyutlu koordinat dönüşümü ve multiquadratik jeoid modellemesi üzerinedir [16, 17].

Bu çalışmada Samsun ili Mert ırmağı havzası ve kent sınırlarının kesiştiği alanda, hâlihazır haritalardan temin edilmiş yatay (X) ve düşey (Y) koordinat bilgilerinin yer aldığı noktalardan yükseklik (Z) değerleri yapay sinir ağları yöntemlerinden Çok Katmanlı Yapay Sinir Ağları (ÇKYSA) ve regresyon analizi kullanılarak tahmin edilmeye çalışılmıştır. Çalışma 3 farklı kombinezon denenmiştir. Bunlar: (i) X koordinat bilgisiyle yükseklik tahmini; (ii) Y koordinat bilgisiyle yükseklik tahmini; (iii) X ve Y koordinat bilgisiyle yükseklik tahmini şeklindedir. Ayrıca çalışmada Samsun ilinde yer alan Mert ırmağı havzasının seçilmesindeki en büyük neden, hidrolik modellemesinin gelecek çalışmalarda yapılabilirliğini araştırmaktır. Hidrolik modellemenin yapılabilmesi için öncelikle çalışma alanı topografyasının modellenmesi gerekmektedir. Bu nedenle bu çalışma ayrıca hidrolik modellemenin de ilk aşamasını oluşturmaktadır.


2. YÖNTEMLER (METHODS)

2.1. Yapay Sinir Ağları, YSA (Artificial Neural Networks, ANN)

Yapay Sinir Ağları (YSA), insan beyninin bilgi işleme tekniğinden esinlenerek geliştirilmiş bir bilgi işlem teknolojisidir. Diğer bir ifadeyle, YSA'lar, normalde bir insanın düşünme ve gözlemlemeye yönelik doğal yeteneklerini gerektiren problemlere çözüm üretmektedir. Bir insanın, düşünme ve gözlemeleme yeteneklerini gerektiren problemlere yönelik çözümler üretebilmesinin temel sebebi ise insan beyninin ve dolayısıyla insanın sahip olduğu yaşayarak veya deneyerek öğrenme yeteneğidir [18].

2.2. Çok Katmanlı Yapay Sinir Ağları, ÇKYSA (Multilayer Artificial Neural Networks, MLANN)

ÇKYSA, birçok işlem elemanlarının birbirlerine farklı ağırlıklarla bağlandığı paralel bir sistemdir. Üç tabakaya sahip ÇKYSA yapısı Şekil 1'de gösterilmektedir. Burada k girdi tabakası, l gizli tabaka ve m çıktı tabakasını göstermektedir. A_{kl} ve A_{lm} ise hücreler arasındaki bağlantılarda oluşan bağlantıların ağırlıklarını temsil etmektedir. Sistemin eğitim aşamasında ağırlık değerleri rastgele sayılar şeklinde atanmaktadır. Bu rastgele atanan ağırlıkların kullanılmasıyla elde edilen çıktıların gerçek (gözlemlenen) çıktı değerleriyle karşılaştırılması sonucunda ağırlıklar yenilenmektedir. Ağırlıkların yenilenmesi ise hata değerinin belirlenen minimum hata değerine yaklaşmasına göre değişir. Hataları minimum yapıncaya kadar hatalar, sağ tabakalardan sol tabakalara doğru yayılır. Ağırlıkları ayarlamak için birçok çalışmada Levenberg-Marquardt (LM) fonksiyonu diğer fonksiyonlara göre daha hızlı ve başarılı sonuçlar verdiği için bu çalışmada LM fonksiyonu kullanılmıştır [19]. Şekil 1'de l ve m tabakalarındaki her bir hücre, önceki tabakadan NET ağırlıklı toplam çıktılarını girdi olarak almaktadır. NET değerleri denklem 1 yardımıyla hesaplanmaktadır [20].



Şekil 1. Üç katmanlı (k,l,m tabakaları) bir YSA yapısı (An ANN structure with three layers (layers k, l, m))

$$NET_{il} = \sum_{k=1}^D A_{kl} C_{tk} + \theta_l \quad (1)$$

Burada, θ_l taraflılık sabiti (bias), A_{kl} giriş ve ara tabakaları arasındaki ağırlıklar kümesi, D girdi vektörünün boyutu, C_{tk} t örneği için giriş tabakasının çıktı kümesidir.

2.3. Regresyon Analizi (Regression Analysis)

Regresyon analizi bağımlı değişken ile bir veya daha çok bağımsız değişken arasındaki ilişkiyi incelemek amacıyla kullanılan bir analiz yöntemidir. Birden fazla bağımsız değişkenin kullanıldığı regresyon analizi çok değişkenli regresyon analizi, tek bir bağımsız değişkenin kullanıldığı regresyon analizi ise tek değişkenli regresyon analizi olarak adlandırılır [21].

2.3.1. Tek değişkenli regresyon analizi, TDR (Univariate regression analysis, URA)


TDR, bir bağımlı değişken ve bir bağımsız değişken arasındaki ilişkiyi inceler. TDR ile bağımlı ve bağımsız değişkenler arasındaki ilişkiyi temsil eden bir doğrunun denklemi formüle edilir. TDR'nin genel yapısı $y=a_1.x_1+b_0+\varepsilon_i$ şeklindedir. Burada “y” bağımlı değişkeni; “x” bağımsız değişkeni; b_0 regresyon eğrisinin y eksenini kestiği noktayı ve ε_i ortalaması sıfır, varyansı σ_2 olan hata değişkenini temsil eder.

2.3.2. Çok Değişkenli Regresyon Analizi, ÇDR (Multivariate regression analysis, MRA)

ÇDR, bir adet bağımlı değişken ve birden fazla bağımsız değişkenin arasındaki ilişkiyi inceler. ÇDR'nin genel yapısı $y=a_1.x_1+a_2.x_2+a_3.x_3+\dots+a_n.x_n+b_0+\varepsilon_i$ şeklindedir. Burada “y” bağımlı değişkeni; “x” bağımsız değişkenleri; b_0 regresyon eğrisinin y eksenini kestiği noktayı ve ε_i ortalaması sıfır, varyansı σ_2 olan normal dağılışa sahip hata değişkenini temsil eder.

3. ÇALIŞMA ALANI VE VERİ (STUDY AREA AND DATA)

Çalışmada Samsun, merkez ilçe sınırlarında yer alan ve Karadeniz'e dökülen Mert ırmağı (enlem: 41.279° ve boylam: 36.352°) havzası çalışma alanı olarak seçilmiştir. Çalışma alanı Şekil 2'de gösterilmektedir.



Şekil 2. Çalışma alanı (Study area) [22].

Çalışmada modellenen veriler Samsun merkez belediyelerinden (Canik-İlkadım) temin edilen hâlihazır harita yükseklik verileridir. Bu veriler 1/1000 ölçekli, ED-50 koordinat datumunda tanımlı olup 2005 yılı hava fotoğraflarından elde edilmiştir. Verilere ait tanımlayıcı istatistiksel veriler Tablo 1'de yer almaktadır.

Tablo 1. Verilere ait istatistiksel bilgiler (Statistics information for data)

	X koordinatları	Y koordinatları	Z (kot)
Veri sayısı (N-adet)	14362	14362	14362
Maksimum değeri (m)	4572051.1	530920.6	238.13
Minimum değeri (m)	4568584.6	528296.48	0.07
Ortalama (m)	4570318.4	529557.4	43.68
Standard sapma (m)	889.7	686.63	52.35
Çarpıklık katsayısı (m)	0.008	0.057	1.429


Tablo 1 incelendiğinde kontrol noktalarının X ve Y koordinat değerlerinde standart sapma değeri, Z değerlerinden daha büyüktür. Bu durum çalışma alanının büyüklüğünün ve çalışmada kullanılan noktaların birbirine yakınlığının bir ölçütüdür. Çarpıklık katsayıları ise X ve Y koordinat değerlerinde birbirine ve sıfıra oldukça yakınsa, Z değerlerinde sıfırdan büyüktür. Normal dağılımda çarpıklık katsayısı sıfıra eşittir. Bu durum göz önüne alındığında X ve Y koordinat değerlerinin normal dağılıma yakın bir dağılım gösterdiği, Z değerlerinin çarpıklık katsayısı ise sıfırdan büyük ve işaretinin

pozitif olması nedeniyle normal dağılıma göre sola çarpık bir dağılım gösterdiği söylenebilir.

Çalışmada toplamda 14362 adet kontrol noktası bulunmaktadır. YSA modellemelerinde veri sayısının fazla olması çalışmanın doğruluğunu etkilemektedir. Veri sayısının fazla olması yapay sinir ağlarında daha fazla deneme-yanılma yapmaya imkan vereceğinden çalışmanın doğruluğunu genellikle artırmaktadır. YSA eğitim aşamasında öğrenme işleminin iyi yapılması, test aşamasında daha doğru tahmin sonuçlarının elde edilmesini sağlamaktadır. Ayrıca YSA modellemelerinde veri kalitesi ve veri parametrelerinin seçimi de çalışmanın doğruluğunu etkilemektedir.

3. UYGULAMA (APPLICATION)

Çalışmada modellemeler MATLAB ortamında gerçekleştirilmiştir. Modelleme kombinezonları Microsoft Excel ortamında oluşturulmuş ve MATLAB ortamında hazırlanmış kodlar yardımıyla veriler modele çağrılarak sonuçlar elde edilmiştir. ÇKYSA ve regresyon modellemeleri iki aşamada (eğitim, test) gerçekleştirilmiştir. Eğitim aşamasında verilerin %80'i test aşamasında ise verilerin %20'si kullanılmıştır. Eğitim ve test verilerinin rastgele dağılımı Şekil 3'de, verilere ait istatistiki bilgileri ise Tablo 2, 3'de yer almaktadır.



Şekil 3. Eğitim ve test verilerinin dağılımı (Distribution of training and test data)

Tablo 2. Eğitim verilerine ait istatistiki bilgiler (Statistics information for training phase)

Veri Seti	Eğitim		
Değişken	X	Y	Z
Veri Sayısı	10053		
Maksimum	4572051.2	530920.69	238.13
Minimum	4568584.6	528298.59	0.07
Ortalama	4570320.4	529553.52	43.53
Standard sapma	888.41	685.23	52.12

Tablo 3. Test verilerine ait istatistiki bilgiler (Statistics information for testing phase)

Veri Seti	Test		
Değişken	X	Y	Z
Veri Sayısı	4309		
Maksimum	4572049.9	530919.13	236
Minimum	4568586.8	528296.48	0.07
Ortalama	4570314.1	529566.54	44.05
Standard sapma	892.78	689.89	52.88

Modellemelerde üç farklı giriş kombinezonu denenmiş olup bunlar: (i) X; (ii) Y; (iii) X, Y; şeklindedir. ÇKYSA modellemesi TDR ve ÇDR ile karşılaştırılmıştır. Karşılaştırma kriterleri olarak Karekök Ortalama Karesel Hata (KOKH), Ortalama Mutlak Hata (OMH) ve determinasyon katsayısı (R^2) kullanılmıştır. KOKH, OMH ve R^2 formülleri denklem 2-4'de yer almaktadır.

$$KOKH = \sqrt{\frac{1}{N} \sum_{i=1}^N (Z_t - Z_g)^2} \quad (2)$$

$$OMH = \frac{1}{N} \sum_{i=1}^N |Z_t - Z_g| \quad (3)$$

$$R^2 = \left(\frac{N * (\sum Z_g * Z_t) - (\sum Z_g) * (\sum Z_t)}{\sqrt{(N * \sum Z_g^2) - (\sum Z_g)^2} * \sqrt{(N * \sum Z_t^2) - (\sum Z_t)^2}} \right)^2 \quad (4)$$

Yukardaki eşitliklerde Z_t ve Z_g tahmin edilen ve gözlenen Z değerlerini, N ise veri sayısını göstermektedir.


ÇKYSA modellemesinde iterasyon sayısı optimize edilmiş ve 100 olarak alınmıştır. Hedef hata değeri ise 1×10^{-5} olarak tanımlanmıştır. Ara tabaka hücre sayısı 10 tabakaya kadar denenmiştir. Eğitim algoritması olarak LM algoritması, aktivasyon fonksiyonu olarak da logsig kullanılmıştır. Aktivasyon fonksiyonu YSA hücrelerine gelen net girdiyi işleyerek hücrenin bu girdiyeye karşılık elde edeceği çıktıyı belirler. Uygulamada fonksiyonun en aktif bölgesi olan 0.2 ile 0.8 arasında veriler normalize edilmiştir. ÇKYSA'da, eğitim aşamasında elde edilen (eğitilen veriler için) optimum ara tabaka hücre sayısı tespit edilmiş ve test aşamasında kontrol edilmiştir. ÇKYSA için farklı ara tabaka hücre sayıları denenmiş ve değerlendirme aşamasında en küçük karesel hatayı veren değer esas alınmıştır. Tablo 4'de ÇKYSA'nın test sonuçları verilmiştir. Burada optimum ara tabaka hücre sayıları da görülmektedir. Örneğin (1,7,1); 1 giriş tabaka hücre sayısı, 7 ara tabaka hücre sayısı ve 1 çıkış tabaka hücre sayısına sahip bir ÇKYSA modelini göstermektedir. Tablodan açıkça görüldüğü gibi X, Y girişini kullanan ÇKYSA

modeli diğerlerine göre daha düşük KOKH (12.00 m) ve OMH (7.98 m) ve daha büyük R^2 (0.948) değerleri vermiştir. En kötü sonuç (ii) kombinezondan elde edilmiştir.


Tablo 4. ÇKYSA modellerinin test aşamasındaki hataları (Errors of MLANN models in the testing phase)

Model	Giriş	Yapı	KOKH (m)	OMH (m)	R^2
(i)	X	(1,7,1)	33.08	1094.28	0.608
(ii)	Y	(1,7,1)	47.14	2222.17	0.205
(iii)	X, Y	(2,4,1)	12.00	144.13	0.948

Şekil 4-9'da ÇKYSA'nın test aşamasındaki tahminleri ile gözlenen değerler, gidiş grafiği ve saçılma diyagramı üzerinde karşılaştırılmıştır. Model sonuçlarının gözlenen değerleri genel olarak yakaladığı fakat bazı pik değerleri gerçeğinden daha az tahmin ettiği görülmektedir.




Şekil 4. ÇKYSA tahmin grafiği (iii kombinezonu) (MLANN estimation graph (combination of iii))




ÇKYSA (iii kombinezonu)

Şekil 5. ÇKYSA saçılma grafiği (iii kombinezonu) (MLANN scattering graph (combination of iii))




Şekil 6. ÇKYSA tahmin grafiği (ii kombinezonu) (MLANN estimation graph (combination of ii))




ÇKYSA (ii kombinezonu)

Şekil 7. ÇKYSA saçılma grafiği (ii kombinezonu) (MLANN scattering graph (combination of ii))



Şekil 8. ÇKYSA tahmin grafiği (i kombinezonu) (MLANN estimation graph (combination of i))




ÇKYSA (i kombinezonu)

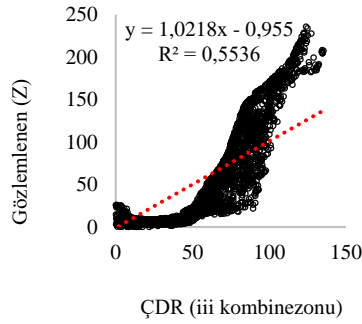
Şekil 9. ÇKYSA saçılma grafiği (i kombinezonu) (MLANN scattering graph (combination of i))

TDR ve ÇDR'ye ait test sonuçları Tablo 5'de verilmiştir. En küçük kareler ile elde edilen regresyon katsayıları da bu tabloda görülmektedir. ÇKYSA sonucuna benzer şekilde en iyi tahmin (iii) kombinezondan elde edilmiştir.


Şekil 10-15'de TDR ve ÇDR'nin test aşamasındaki tahminleri ile gözlenen Z değerleri gösterilmiştir. Şekilden açıkça görüldüğü gibi model, bazı pik değerlerini gerçeğinden çok daha düşük değerlerde tahmin etmiştir.




Şekil 10. ÇDR tahmin grafiği (iii kombinezonu) (MLR estimation graph (combination of iii))




Şekil 11. ÇDR saçılma grafiği (iii kombinezonu) (MLANN scattering graph (combination of iii))




Şekil 12. TDR tahmin grafiği (iii kombinezonu) (URA estimation graph (combination of iii))



Şekil 12. TDR saçılma grafiği (ii kombinezonu) (URA scattering graph (combination of ii))



Şekil 14. TDR tahmin grafiği (i kombinezonu) (URA estimation graph (combination of i))



Şekil 15. TDR saçılma grafiği (i kombinezonu) (URA scattering graph (combination of i))

Tablo 5. ÇDR ve TDR modellerinin test aşamasındaki hataları (Errors of URA and MLR models in the testing phase)

Model	Giriş	Katsayılar a,b	KOKH	OMH	R ²
(i)	X	-0,04; 182583,422	4446,7	19773140	0,463
(ii)	Y	0,03; 14629,515	49,13	2413,81	0,132
(iii)	X, Y	-0,0378; 0,0214; 161549,34	35,33	1248,87	0,541

Tablo 4-5 karşılaştırıldığında ÇKYSA'nın, ÇDR ve TDR'ye göre Z değerlerini daha iyi tahmin ettiği görülmüştür. Şekil 4-15 değerlendirilecek olursa, özellikle saçılma diyagramlarında (eşitliğin $y=ax+b$ olduğunu varsayalım) ÇKYSA (iii kombinezonu) modelinin diğerlerine göre daha iyi tahmin verdiği ve doğrusal eşitlikde a ve b katsayılarının sırasıyla 1 ve 0'a (yani 45° çizgisine) daha yakın olduğu açıkça gözlemlenebilir.

4. TARTIŞMA ve SONUÇLAR (DISCUSSION and RESULTS)

Bu çalışma ile yüzey modellemesinin YSA yardımıyla elde edilebileceği görülmüştür. Elde edilen sonuçlara incelendiğinde YSA modelleri ÇDR ve TDR gibi regrasyon modellerinden oldukça başarılıdır. Bu sonuçlar YSA tekniklerinin hidrolik modellemeler gibi bir çok mühendislik çalışmalarının temel althğını oluşturan yükseklik modellemelerinde kullanılabilir olduğunu göstermektedir.

Yüzey modellemeleri literatürde genellikle regrasyon teknikleri ve matematiksel fonsiyonlar kullanılarak yapılmaktadır [15]. Ayrıca yüzey modellemesiyle ilgili Inverse Distances Weight (IDW), Kriging gibi geoistatistik yöntemler de kullanılmaktadır ve YSA tekniklerinin daha iyi modelleme sonuçları verdiği bilinmektedir [23]. Çalışmada elde edilen sonuçlar bu durumu desteklemektedir.

Topoğrafik yüzeye mühendislik uygulamalarının bir çoğunda ihtiyaç duyulmaktadır. Yapılacak modellemelerde topografyanın uygun doğrulukta belirlenmesi çalışmanın doğruluğunu etkilemektedir. Bu amaçla bu çalışmada, örnek çalışma alanı yatay ve düşey konum bilgileri kullanılarak ara noktaların yükseklik değerlerinin modellemesi yapılmıştır. Modelleme, bilinen fonksiyonların dışında kapalı kutu modeline dayalı yapay sinir ağlarıyla yapılmış ve regrasyon teknikleriyle karşılaştırılmıştır. Çalışma alanı olarak Samsun ili Mert ırmağı havzası ile kentsel bölgelerin kesiştiği alan seçilmiştir. Bu alana ait yükseklik bilgileri hâlihazır haritalardan temin edilmiştir. Modellemede, Çok katmalı Yapay Sinir Ağları (ÇKYSA), tek ve çok değişkenli regrasyon yöntemleri kullanılmıştır. Yöntemlerin performansları incelenmiş ve aşağıdaki sonuçlar elde edilmiştir.

(1) ÇKYSA yöntemi, ÇDR ve TDR yöntemlerine göre Z değerlerini daha iyi tahmin etmektedir

(2) ÇKYSA ile yapılan tahminde en iyi sonucu X, Y koordinat bilgileri (kombinezon iii) kullanılarak yapılan modelleme vermiştir.

(3) ÇDR yöntemi, TDR yöntemine göre daha başarılı sonuçlar vermiştir.

ÇIKAR ÇATIŞMASI BEYANI (CONFLICT OF INTEREST STATEMENT)

Yazarlar tarafından herhangi bir çıkar çatışması bildirilmemiştir.

KAYNAKLAR (REFERENCES)

- [1] Y.C. Fang and B.-W. Wu, "Neural network application for thermal image recognition of low-resolution objects," *J. Opt. A Pure Appl. Opt.*, vol. 9, no. 2, pp. 134–144, January 2007. Doi: 10.1088/1464-4258/9/2/003
- [2] R. Stohl and K. Stibor, "Predicting safety solutions via an artificial neural network," *IFAC-PapersOnLine*, vol. 52, no. 27, pp. 490–495, October 2019. Doi: 10.1016/j.ifacol.2019.12.711
- [3] K. Papik, B. Molnar, R. Schaefer, Z. Dombovari, Z. Tulassay, and J. Feher, "Application of neural networks in medicine - A review," *Med. Sci. Monit.*, vol. 4, no. 3, pp. 538–546, December 1998.
- [4] A. Parlak, Y. Islamoglu, H. Yasar, and A. Egrisogut, "Application of artificial neural network to predict specific fuel consumption and exhaust temperature for a Diesel engine," *Appl. Therm. Eng.*, vol. 26, no. 8–9, pp. 824–828, June 2006. Doi: 10.1016/j.applthermaleng.2005.10.006
- [5] S. Trajkovic, B. Todorovic, and M. Stankovic, "Forecasting of Reference Evapotranspiration by Artificial Neural Networks," *J. Irrig. Drain. Eng.*, vol. 129, no. 6, pp. 454–457, January 2003. Doi: 10.1061/(ASCE)0733-9437(2003)129:6(454)
- [6] X. Yuanyou, X. Yanming, and Z. Ruigeng, "An engineering geology evaluation method based on an artificial neural network and its application," *Eng. Geol.*, vol. 47, no. 1–2, pp. 149–156, August 1997. Doi:10.1016/S0013-7952(97)00015-X
- [7] A. Arı and E. Berberler, "Yapay sinir ağları ile tahmin ve sınıflandırma problemlerinin çözümü için arayüz tasarımı," *ACTA Infologica*, vol. 1, no. 2, pp. 55–73, December 2017.
- [8] V. N. Sharda, R. M. Patel, S. O. Prasher, P. R. Ojasvi, and C. Prakash, "Modeling runoff from middle Himalayan watersheds employing artificial intelligence techniques," *Agric. Water Manag.*, vol. 83, no. 3, pp. 233–242, June 2006. Doi:10.1016/j.agwat.2006.01.003
- [9] M. Kumar and N. Raghuvanshi, "Estimating evapotranspiration using artificial neural network," *J. Irrig. Drain. Eng. J. Irrig. Drain. Eng. and Drainage Engineering*, Vol. 128, no. 4, 454–457, July 2002. Doi:10.1061/(ASCE)0733-9437(2002)128:4(224)
- [10] E. Uzlu, "Türkiye için gri kurt optimizasyon algoritması ile yapay sinir ağlarını kullanarak enerji tüketiminin tahmini," *Gazi Üniversitesi Fen Bilim. Derg. Part C Tasarım ve Teknol.*, vol. 7, no. 2, pp. 245–262, March 2019. Doi:10.29109/gujsc.519553
- [11] M. A. Çavuşlu, Y. Becerikli, and C. Karakuzu, "Levenberg-Marquardt Algoritması ile YSA Eğitiminin Donanımsal Gerçeklenmesi," *Türkiye Bilişim Vakfı Bilgi. Bilim. ve Mühendisliği Derg.*, vol. 5, no. 5, pp. 1–7, June 2012.

- [12] E. Sütçü, "Kaynaklı İmalat Operasyon Sürelerinin Matlab Yapay Sinir Ağları ile Tahmin Edilmesi," *Gazi Mühendislik Bilim. Derg.*, vol. 4, no. 1, pp. 16–24, February 2018. Doi: 10.30855/gmbd.2018.04.01.003
- [13] M. B. Özdemir and M. Galip, "Düşey Tip Toprak Kaynaklı Isı Pompasının Yapay Sinir Ağları İle Ankara Şertlerinde Yaz Mevsimi İçin Performans Tahmini," *Gazi Mühendislik Bilim. Derg.*, vol. 5, no. 1, pp. 46–53, April 2019. Doi:10.30855/gmbd.2019.01.05
- [14] A. Şeker, B. Diri, and H. H. Balık, "Derin Öğrenme Yöntemleri ve Uygulamaları Hakkında Bir İnceleme," *Gazi Mühendislik Bilim. Derg.*, vol. 3, no. 3, pp. 47–64, November 2017.
- [15] L. Cakir and N. Yılmaz, "Polynomials, radial basis functions and multilayer perceptron neural network methods in local geoid determination with GPS/levelling," *Meas. J. Int. Meas. Confed.*, vol. 57, pp. 148–153, November 2014. Doi: 10.1016/j.measurement.2014.08.003
- [16] Leyla Çakir, "Polinomlar, Multiküadrik Enterpolasyon, İleri Beslemeli Yapay Sinir Ağı ve Anfis yöntemleri ile yerel GPS/Nivelman Jeoidin belirlenmesi", in 8. *Ulusal Mühendislik Ölçmeleri Sempozyumu, 19-21 Ekim, 2016, İstanbul, Türkiye*, E. Güllal and B. Akpınar, Ankara: Harita ve Kadastro Mühendisleri Odası, 2016. pp. 1–9.
- [17] B. Konakoglu, L. Cakir, and E. Gökalp, "2D coordinate transformation using artificial neural networks," *Int. Arch. Photogramm. Remote Sens. Spat. Inf. Sci. - ISPRS Arch.*, vol. 42, no. 2W1, pp. 183–186, October 2016. Doi: 10.5194/isprs-archives-XLII-2-W1-183-2016
- [18] URL1," *"Yapay sinir ağları"*, wikipedia, 2010, [Online]. Available: https://tr.wikipedia.org/wiki/Yapay_sinir_ağları, [Accessed: Sept. 12, 2010].
- [19] D. W. Marquardt, "An algorithm for least-squares estimation of nonlinear parameters," *J. Soc. Indust. Appl. Math.*, vol. 11, no. 2, pp. 431–441, June 1963. Doi:10.1137/0111030
- [20] M. Fırat and M. Güngör, "Askı Madde Konsantrasyonu ve Miktarının Yapay Sinir Ağları ile Belirlenmesi," *İMO Tek. Dergi*, vol. 15, no. 73, pp. 3267–3282, February 2004.
- [21] URL-2, "Regresyon Analizi", istatistik analiz, 2010, [Online]. Available: http://www.istatistikanaliz.com/regresyon_analizi.asp. [Accessed: Sept. 12, 2010].
- [22] V. Demir and A. Ülke, "Manning Pürüzlülük Katsayısının Cowan Yöntemi ve Uzaktan Algılama Yardımıyla Belirlenmesi," *Gazi Mühendislik Bilim. Derg.*, vol. 5, no. 2, pp. 167–177, August, 2019. Doi:10.30855/gmbd.2Q19.02.06
- [23] V. Demir, E. A. Cubukcu and M. F. Sevimli, "Long-Term Month Temperature forecast with Inverse Distances Weighted, Kriging and Artificial Neural Networks," in *2nd Cilicia International Symposium on Engineering and Technology, CİSET 2019, October 10-12, 2019, Mersin, Turkey*, M. Yakar, E. Avaroglu and C. Aci, Ankara: SAGE, 2019. pp. 10-16.

Vahdettin DEMİR

Vahdettin DEMİR 1992 yılında Gümüşhane'nin Kelkit ilçesinde dünyaya geldi. İlk, orta ve lise eğitimini Kelkit'te tamamladı. 2009 yılında girdiği Gümüşhane Üniversitesi Mühendislik Fakültesi İnşaat Mühendisliği bölümünden 2013 yılında birincilikle mezun oldu. Ayrıca 2010 yılında Jeodezi ve Fotoğrametri Mühendisliği bölümünde Çift Anadal Programına katıldı ve 2013 yılında bölüm birinciliğiyle mezun oldu. 2013 yılında Yüksek Lisans eğitimine başladı. 2015 yılında Yüksek Lisans programını tamamlayarak 2016 yılında Ondokuzmayıs Üniversitesi İnşaat Mühendisliği bölümü, hidrolik anabilim dalında doktora eğitimine başladı. Taşkın modellemesi, yapay zeka, trend analizi ve uzaktan algılama alanlarında doktora çalışmalarına devam eden Demir evli ve bir çocuk sahibidir.

Aslı ÜLKE KESKİN

Aslı ÜLKE KESKİN 1974 yılında Konya'da dünyaya geldi. Lisans eğitimini 2000 yılında Süleyman Demirel Üniversitesi'nde tamamladı. Aynı üniversitede 2003 yılında yüksek lisans eğitimini tamamlayarak Dokuz Eylül Üniversitesi'nde Doktora eğitimine başladı. 2010 yılında doktorasını tamamlayarak 2011 yılında Ondokuz Mayıs Üniversitesi, İnşaat Mühendisliği Bölümü, Hidrolik Anabilim dalına Dr. Öğr. Üyesi olarak atandı ve halen aynı üniversitede çalışmaktadır. Keskin ileri seviyede İngilizce bilmektedir. Sediment taşınımı, Küresel iklim değişikliği, Kuraklık indisleri, Taşkın ötelenmesi, Yapay sinir ağları, ANFIS ve optimizasyon konularında çalışmaktadır. Evli ve bir çocuk sahibidir.