

Yapay sinir ağları kullanarak iklim parametrelerinden Pan buharlaşmanın tahmin edilmesi

Cafer GENÇOĞLAN¹, Hasan BADEM²

Geliş Tarihi: 09.10.2024 / Kabul Tarihi: 13.11.2024

Öz: Çalışmanın amacı, A sınıfı buharlaşma kabından olan buharlaşmanın (Ep) rüzgar hızı, solar radyasyon, sıcaklık ve oransal nem değerlerini kullanarak yapay sinir ağlarından (YSA) tahmin etmektir. Gizli katmandaki nöron sayısı 5, 7 ve 10 olarak seçilmiştir. YSA modelinin eğitilmesinde tansig ve pureline aktivasyon fonksiyonu; eğitim algoritması olarak Levenberg-Marquardt (LM), Scaled conjugate gradient (SCG) ve Resilient Propagation (RP) kullanılmıştır. ANN modelleri 250, 500, 750 ve 1000 kez yineleme (epochs) yapılarak eğitilmiştir. Bu sayede 36 farklı YSA modeli elde edilerek sonuçlar rapor edilmiştir. Modellerin tahmin yeteneğinin değerlendirilmesinde Belirleme Katsayısı (R^2), Ortalama Mutlak Hata (MEA) ve Tahmin Hatası Standart Sapması (RMSE) istatistiksel yöntemleri kullanılmıştır. Önerilen yöntemin eğitim sürecinde R^2 'den 0.76-0.88, MEA'dan 0.88-1.34 (mm) ve RMSE'den 1.13-1.65 (mm) değerleri elde edilmiştir. Önerilen yöntemin test sürecinde ise R^2 'den 0.49-0.788, MEA'dan 1.19-2.11 (mm) ve RMSE'den 1.58-2.19 (mm) değerleri elde edilmiştir. Elde edilen deneysel sonuçlarda göre eğitim sürecinde 36 farklı model arasında en başarılı olan model ((LM,4-7-1) ve 250 yineleme) ile R^2 , MEA ve RMSE'ı sırasıyla 0.86, 0.97 ve 1.254 skorları elde edilmiştir. Test sürecinde ise en başarılı modelden ((LM,4-7-1) ve 500 yineleme) R^2 , MEA ve RMSE'ı ise sırasıyla 0.79, 1.195 ve 1.579 skorları elde edilmiştir. Bu modele göre belirleme katsayısı bağımlı değişken, bağımsız değişkeni %79 oranında temsil etmektedir. MEA ve RMSE istatistiğine göre YSA ile tahmin edilen değerler (TEp) ile ölçülen değerler (OEp) arasındaki hata sırasıyla 1.195 mm ve 1.579 mm olarak belirlenmiştir.

Anahtar Kelimeler: İklim verisi, Pan buharlaşma, Yapay sinir ağı, LM, RMSE

Prediction of Pan evaporation from climate parameters using artificial neural networks

Abstract: The aim of the study is to predict the evaporation (Ep) from the Class A evaporation pan using wind speed, solar radiation, temperature and relative humidity values in the artificial neural network (ANN). The number of neurons in the hidden layer was selected as 5, 7 and 10. In the training of the ANN model, Tansig and pureline have been used as activation functions, and Levenberg-Marquardt (LM), Scaled conjugate gradient (SCG) and Resilient Propagation (RP) have been utilized as training algorithm. The ANN models have been trained over 250, 500, 750 and 1000 iterations (epochs). Hence, 36 different ANN models have been obtained and the results have been reported. Coefficient of Determination (R^2), Mean Absolute Error (MEA) and Root Mean Square Error (RMSE) statistical metrics were used to evaluate the prediction ability of the models. In the training process of the proposed method, values of 0.76-0.88 from R^2 , 0.88-1.34 (mm) from MEA and 1.13-1.65 (mm) from RMSE have been obtained. In the test process of the proposed method, values of 0.49-0.788 from R^2 , 1.19-2.11 (mm) from MEA and 1.58-2.19 (mm) from RMSE have been obtained. According to the experimental results, the most successful model among 36 different models in the training process ((LM,4-7-1) and 250 epochs) obtained R^2 , MEA and RMSE scores of 0.86, 0.97 and 1.254, respectively. In the testing process, the most successful model (LM,4-7-1) and 500 epochs) obtained R^2 , MEA and RMSE scores as 0.79, 1.195 and 1.579, respectively. According to this model, the coefficient of determination dependent variable represents the independent variable by 79%. According to MEA and RMSE statistics, the error between the values estimated by ANN (TEp) and the measured values (OEp) were determined as 1.195 mm and 1.579 mm, respectively.

Keywords: Climate data, Pan evaporation, Artificial neural network, LM, RMSE

Giriş

A sınıfı kaptan atmosfere olan buharlaşma, hidrolojik ve su kaynakları çalışmalarında her zaman önemli bir rol oynamıştır. Buharlaşma miktarı, su kaynakları yönetimi (Chin ve Zhao, 1995; Yahaya ve

¹ Kahramanmaraş Sütçü İmam Üniversitesi, Ziraat Fakültesi, Biyosistem Mühendisliği Bölümü, Kahramanmaraş, Türkiye

² Kahramanmaraş Sütçü İmam Üniversitesi, Mühendislik ve Mimarlık Fakültesi, Bilgisayar Mühendisliği Bölümü, Kahramanmaraş, Türkiye

*Sorumlu yazar: gencoglan@ksu.edu.tr

Cite/Atıf:

Gençoğlan, C., Badem, H. (2024). Yapay sinir ağları kullanarak iklim parametrelerinden Pan buharlaşmanın tahmin edilmesi. *AgriTR Science*, 2024, 6(2): 122-128.

Copyright © 2024 by AgriTR Science.

This work is licensed under a Creative Commons Attribution-Non Commercial 4.0 International License.



Ark., 2018) ve iklim değişikliği çalışmaları (Burn ve Hesch 2007) için önemlidir. A sınıfı kap buharlaşma miktarına radyasyonun, rüzgar hızının, sıcaklığın ve nemin bütünleşik etkisi olduğu için (Doorenbos ve Pruitt, 1977; Ertek, 2011) hem yurt içinde hem de yurt dışında A sınıfı buharlaşma kabı kullanılarak tarla ve bahçe bitkilerinde sulama programının oluşturulmasına yönelik çalışmalar yürütülmüştür. Bu çalışmalar sonucunda A sınıfı buharlaşma kabının sulama programının oluşturulmasında kullanılabilirliğini ortaya konulmuştur (Allen ve Ark., 1998; Ertek ve Ark., 2006; Gençoğlu, Ark., 2019). Diğer yandan bu kap, standart buharlaşma ölçüm cihazına dönüştürülmüştür (Burgess ve Hanson, 1981). Kullanım kolaylığı, verilerin basitliği ve düşük maliyet avantajlarından dolayı birçok ülkede geniş çapta uyarlanması teşvik edilmiştir (Hatfield, 1990). Ancak A sınıfı buharlaşma kabından olan günlük buharlaşma miktarının ölçümü ve yönetimi (yer seçimi, su dolumu, kabın büyüklüğü, yosun temizliği, etrafında yetişen bitkilerin temizliği vb) önemli bir problem olarak görülmektedir. Bu problem, mevcut teknolojiler kullanarak azaltılabilir.

Günümüzde pek çok mühendislik problemlerinde umut vaaden yapay zeka çalışmalarında Yapay Sinir Ağları (YSA) mimarileri öne çıkmaktadır (LeCun ve Ark. 2015, Innci ve Badem 2023, Wiegbe 2024). Dolayısıyla, yapay zekâ alanının bir alt dalını oluşturan bu teknoloji, öğrenebilen sistemlerin temelini oluşturmaktadır. YSA, insan beyninin temel işlem birimi olan nöronu (neuron) (Villarreal, 2007) ve aksiyonlarını, ilişkisel fonksiyon olarak modelleyen (Leverington, 2009) sistemdir. İnsanoğlunun deneyerek (yaşayarak) öğrenme yeteneği, YSA'ında verilerden öğrenme ye karşılık gelmektedir. Gün geçtikçe de gelişen bu teknolojiden, günümüzde birçok alanda faydalanılmaktadır (Yurtoğlu, 2005, Wiegbe 2024).

YSA'da öğrenme ile hafızaya alma ve veriler arasındaki ilişkiyi ortaya çıkarılmaktadır. YSA, 1943 yılında yapay sinir tanımını yaparak bir hücre modeli geliştiren McCullogh ve Pitts tarafından başlatıldığı kabul edilir (McCullogh ve Pitts, 1943). Çalışmalarında sinir hücrelerini sabit eşik değerli mantıksal elemanlar olarak modellemiştir. Daha sonra öğrenme üzerine çalışmaların yoğunlaştığı 1949 yılında Hebb, yapay sinir ağlarındaki öğrenme için başlangıç noktası sayılayan optimizasyon modelini geliştirmiştir (Hebb,1949). Genel olarak YSA; 3 katman halinde ve her katman içinde paralel olarak bir araya gelen nöronlar ile ağı oluşturulmaktadır. Bu katmanlar; girdi katmanı, ara katmanlar (gizli katman) ve çıktı katmanıdır. Bir yapay sinir hücresi (nöron), kendisine gelen bir giriş değerini, kendisine gelen birden fazla bağlantıya ait ağırlık değerleri ile çarparak toplamını hesaplar. Sonra toplam değerini etkinlik fonksiyonundan geçirerek bir sonraki katmana çıkış olarak iletir (Kurucan ve Ark. 2024) . Çok katmanlı ağlarda, ara katmanlarda genellikle sigmoid etkinlik fonksiyonu, çıkış katmanında ise lineer etkinlik fonksiyonu kullanılır (Jang, 1993). Gizli katman bazen birden fazla da olabilir. Girdi katmanı, dış dünyadan girdileri alarak gizli katmana gönderir. Gizli katman, bu girdileri işleyerek çıktı katmanına, çıktı katmanı da gelen bilgileri işleyerek dış dünyaya gönderir (Öztemel, 2003, Montesinos ve Ark. 2022).

Yurtoğlu (2005)' ya göre, YSA, birbirlerine bağlanmış birçok işlem elemanlarından (nöronlar) oluşan matematiksel sistemlerdir. Ağda bulunan her işlem elemanı belli bir ağırlığa sahiptir. İşlem elemanları, transfer fonksiyonu olarak adlandırılan denklemlerdir. Bu işlem elemanları, dış dünyadan veya kendisine girdi sağlayan diğer nöronlardan sinyalleri alarak birleştirir ve dönüştürerek sayısal bir sonuç üretir. İnsan beyni sinir hücrelerinde bu işlem sırasıyla; dentrit, hücre gövdesi ve akson tarafından gerçekleştirilir. Gerçek nöronların uzak bir taklidi olarak değerlendirilen işlem elemanları, belli bir düzen içerisinde birbirlerine bağlanarak yapay sinir ağlarını oluştururlar. YSA'nın çoğunda, benzer karakteristiğe sahip nöronlar tabakalar halinde yapılandırılırlar ve transfer fonksiyonları eş zamanlı olarak çalıştırılırlar. Hemen hemen tüm ağlarda, veri alan nöronlar ve çıktı üreten nöronlar mevcuttur

YSA, farklı iklim koşullarında buharlaşmanın tahmininde kullanılmıştır. Bu çalışmalardan konuya yakın olan bir kısmı bu makalede verilmiştir. Kişi (2006) yapay sinir ağları ile farklı meteorolojik verileri kullanarak buharlaşmanın modellenmesi tahmin etmiştir. Sudheer ve Ark. (2002) çok değişkenli hidrolojik modellerin oluşturulmasında Radyal tabanlı yapay sinir ağlarını kullanarak gölde meydana gelen günlük buharlaşmayı hesaplamışlardır. Terzi ve Keskin (2005) yapay sinir ağlarında genelleştirilmiş regresyon modeli ile A sınıfı kabından olan buharlaşmayı kestirmeye çalışmışlardır. Doğan ve Işık (2005), Yıldırım ve Ark. (2019), Chung


ve Ark. (2012), Yıldırım ve Ark. (2019) yaptıkları çalışma farklı meteorolojik parametreleri kullanarak YSA ile buharlaşma tahmini yapmışlardır.

Bu çalışmanın amacı A sınıfı buharlaşma kabından olan buharlaşma (E_p)'yı rüzgar hızı, solar radyasyon, sıcaklık ve nem değerlerini kullanarak yapay sinir ağları (YSA) aracılığı ile tahmin ettirmektedir.

Materyal Metot

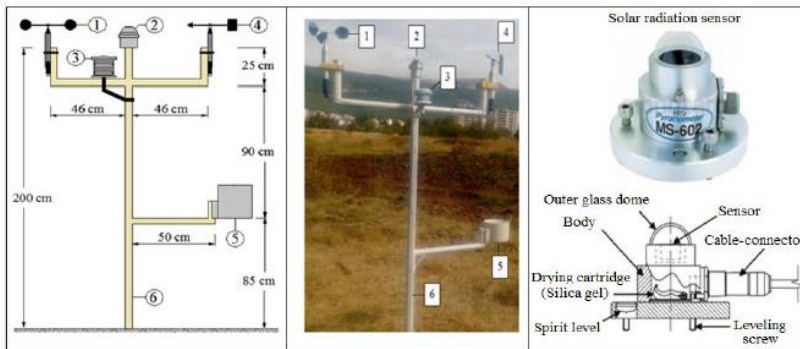
Bu çalışmada A sınıfı buharlaşma kabından olan buharlaşma (E_p)'yı rüzgar hızı, solar radyasyon, sıcaklık ve nem değerlerini kullanarak yapay sinir ağları (YSA) aracılığı ile tahmin edilmiş ve sonuç karşılaştırılmıştır. Çalışma, Kahramanmaraş Sütçü İmam Üniversitesi Ziraat Fakültesi Uygulama Bahçesinde yürütülmüştür.

Pan buharlaşma (E_p)'nın ölçülmesinde en çok standart A sınıfı buharlaşma kabı (Class A Pan) kullanılmaktadır. A sınıfı buharlaşma kabının yerleştirildiği alanın etrafında meyve bahçeleri vardır. Kap, 10 cm yüksekliğinde ızgara üzerine yerleştirilmiştir. Yaban hayvanların kaptan su içmesini önlemek için üzere ızgaralı telle kapatılmıştır. A sınıfı buharlaşma kabı E_p , A sınıfı buharlaşma kabından mikrometre aracılığı ile elle ölçülmektedir. Ancak bu çalışmada 2019 yılı yaz dönemine ait E_p değerleri, programlanabilir lojik kontrol (PLC) ve ultrasonik sensör kullanılarak yapılan ölçümlerden hesaplanmıştır. A sınıfı buharlaşma kabı; 121 cm çapında, 25.5 cm yüksekliğinde, galvanizli sacdan yapılmış üstü açık silindirden ibarettir (Şekil 1). Ultrasonik sensör kullanılarak A sınıf buharlaşma kabından su derinliği ölçümü yöntemi Gençoğlan ve Ark. (2023)'te ayrıntılı olarak verilmiştir.



Şekil 1. A Sınıfı buharlaşma kabı (Gençoğlan, 2023).

Rüzgar hızı, solar radyasyon, sıcaklık ve oransal nem gibi iklim faktörleri A sınıfı buharlaşmadan olan buharlaşma (E_p)'yi etkileyen en önemli etmenlerdendir. Bu iklim parametreleri Şekil 2'de verilen iklim istasyonunda ölçülmüştür. Rüzgar hızı, anometre; radyasyon, pyronometre; sıcaklık, sıcaklık sensörü ve oransal nem, nem sensörü kullanılarak ölçülmüştür. Rüzgar hızı, sıcaklık ve oransal nem günlük ortalama; solar radyasyon ise günlük toplam değeridir (Usta ve Ark., 1922).



Şekil 2. 1, rüzhar hızı sensörü (U, m/sn); 2, solar radyasyon sensor (SR, $MJ m^{-2} day^{-1}$); 3, hava sıcaklığı ($T, ^\circ C$) ve oransal nem (RH, %) (Usta ve Ark., 2022).

Günlük pan buharlaşmasını (Ep) tahmin etmek için giriş, bir gizli ve çıkış katmanından oluşan YSA modeli tanımlanmış ve kullanılmıştır. Gizli katmandaki nöron sayısı deneme yanılma yöntemiyle 5, 7 ve 10 olacak şekilde farklı değerler belirlenmiştir (Şekil 3). YSA modelinde eğitilmesinde tansig ve pureline aktivasyon fonksiyonu kullanılmıştır. Eğitim algoritması olarak Levenberg-Marquardt (LM), Scaled conjugate gradient (SCG) ve Resilient Propagation (RP) kullanılmıştır. Elde edilen sonuçlar 250, 500, 750 ve 1000 kez iterasyon (epochs) yapılarak hesaplanan değerler ile karşılaştırılmıştır.

Çalışmada, 123 adet rüzgar hızı, solar radyasyon, sıcaklık ve oransal nem değerleri ölçülmüştür. Bu 123 değerden rastgele seçilen %70'i (87 adedi) eğitim verisi ve aynı yöntemle seçilen %30'luk (36 adedi) kısım test verisi olarak kullanılmıştır.


Modellerin tahmin yeteneğinin belirlenmesinden kullanılan belirleme katsayısı (R^2), MEA ve RMSE istatistiksel yöntemleri Eşitlik 1, 2 ve 3'de verilmiştir. R^2 , bağımlı değişkenlerin (OE_{pi}) bağımsız değişkenleri (TE_{pi}) temsil etme oranını göstermektedir ve 0-1 arasında değişmektedir. Ortalama mutlak hata (MAE), sapmanın miktarını gösterir ve 0 ile ∞ arasında değerler alır (Lewis, 1982). Değer ne kadar düşükse o kadar iyi performans elde edilir. Tahmin Hatası Standart Sapması (RMSE), ölçüm değerleri ile model tahminleri arasındaki hata oranını belirlemek amacıyla kullanılmaktadır. Sıfıra yakın değerler, tahmin gücünün yüksek olduğunu göstermektedir (Yıldırım ve Ark., 2019).

$$R^2 = \frac{\sum_{i=1}^n (TE_{pi} - OE_{pi})^2}{\sum_{i=1}^n (TE_{pi} - OE_{pi})^2} \quad (1)$$

$$MAE = \frac{\sum_{i=1}^n |TE_{pi} - OE_{pi}|}{n} \quad (2)$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (OE_{pi} - TE_{pi})^2}{n}} \quad (3)$$

Eşitliklerde, OE_{pi} ; A sınıfı buharlaşma kabında ölçülen Ep değerleri (mm), TE_{pi} ; YSA ile tahmin edilen Ep değerleri (mm)'dir.



Şekil 3. Önerilen YSA mimarisi

Çalışmada Ep'yi tahmin etmek için MATLAB'ın YSA uygulamalarından Regresyon Öğrenme (Regression Learner) modeli seçilmiştir. Newff: ileri beslemeli geri yayılma ağ (feed-forward backpropagation network)'dir. Bu fonksiyondaki minmax fonksiyonu, matrisin satırındaki en düşük ve en yüksek değerini döndürmektedir. Tansig ve pureline, sırasıyla tanjant sigmoid hiperbolik teğet ve lineer transfer fonksiyonlarıdır. Trainlm, ağırlık ve bias değerlerini Levenberg-Marquardt optimizasyonuna göre güncelleyen bir ağ eğitim fonksiyonudur. Trainlm, genellikle kullanılan geri yayılım algoritmasını barındırır. Bu nedenle denetimli (supervised) algoritma olarak tavsiye edilmektedir (Matlab 2024).

Bulgular ve Tartışma

A sınıfı buharlaşma kabından olan buharlaşma (Ep), rüzgar hızı, solar radyasyon, sıcaklık ve nem değerlerini kullanarak YSA aracılığı ile tahmin edilmiştir. Günlük Ep'yi tahmin etmek için tek katmanlı YSA kullanılmıştır. Gizli katmandaki nöron sayısı 5, 7 ve 10 olarak seçilmiştir. YSA modelinde eğitilmesinde tansig ve pureline aktivasyon fonksiyonu; eğitim algoritması olarak LM, SCG ve RP kullanılmıştır. Elde edilen sonuçlarda 250, 500, 750 ve 1000 kez yinleme (epochs) yapılarak hesaplanan değerler ile karşılaştırılmıştır. Modellerin tahmin başarısının değerlendirilmesinde R^2 , MAE ve RMSE istatistiksel yöntemleri kullanılmıştır. Yukarıda verilen parametreler kullanılarak elde edilen sonuçlar Çizelge 1'de verilmiştir.

Çizelge 1. Bazı iklim parametresinin kullanarak çeşitli YSA modellerinin Ep tahmin yeteneğini değerleri


Model	Ağ yapısı	Yinleme	Eğitim			Test		
			R^2	MAE	RMSE	R^2	MAE	RMSE
M1	(LM,4-5-1)	250	0.854	0.972	1.295	0.644	1.566	2.109
	(LM,4-5-1)	500	0.833	1.071	1.384	0.700	1.510	1.922
	(LM,4-5-1)	750	0.835	1.027	1.374	0.645	1.630	2.045
	(LM,4-5-1)	1000	0.827	1.006	1.408	0.645	1.630	2.045
M2	(LM,4-7-1)	250	0.863	0.969	1.254	0.625	1.860	2.265
	(LM,4-7-1)	500	0.809	1.110	1.479	0.788	1.195	1.579
	(LM,4-7-1)	750	0.836	1.046	1.371	0.603	1.714	2.179
	(LM,4-7-1)	1000	0.882	0.838	1.164	0.491	2.110	2.630
M3	(LM,4-10-1)	250	0.832	1.052	1.385	0.579	1.690	2.237
	(LM,4-10-1)	500	0.791	1.187	1.546	0.731	1.490	1.818
	(LM,4-10-1)	750	0.791	1.197	1.548	0.581	1.579	2.915
	(LM,4-10-1)	1000	0.791	1.197	1.548	0.562	1.856	2.299
M1	(SCG,4-5-1)	250	0.786	1.263	1.565	0.685	1.437	1.924
	(SCG,4-5-1)	500	0.786	1.268	1.565	0.752	1.299	1.722
	(SCG,4-5-1)	750	0.801	1.182	1.508	0.715	1.378	1.839
	(SCG,4-5-1)	1000	0.785	1.267	1.569	0.755	1.290	1.708
M2	(SCG,4-7-1)	250	0.786	1.260	1.570	0.738	1.402	1.787
	(SCG,4-7-1)	500	0.784	1.279	1.574	0.740	1.347	1.768
	(SCG,4-7-1)	750	0.796	1.210	1.528	0.747	1.354	1.754
	(SCG,4-7-1)	1000	0.807	1.216	1.487	0.702	1.446	1.883
M3	(SCG,4-10-1)	250	0.795	1.251	1.536	0.734	1.402	1.807
	(SCG,4-10-1)	500	0.822	1.146	1.427	0.725	1.417	1.824
	(SCG,4-10-1)	750	0.761	1.339	1.653	0.749	1.319	1.731
	(SCG,4-10-1)	1000	0.851	1.005	1.304	0.709	1.417	1.853
M1	(BR,4-5-1)	250	0.818	1.154	1.445	0.717	1.513	1.847
	(BR,4-5-1)	500	0.818	1.154	1.445	0.717	1.513	1.847
	(BR,4-5-1)	750	0.818	1.154	1.445	0.717	1.513	1.847
	(BR,4-5-1)	1000	0.818	1.154	1.445	0.717	1.513	1.847
M2	(BR,4-7-1)	250	0.815	1.177	1.459	0.729	1.453	1.805
	(BR,4-7-1)	500	0.848	1.008	1.319	0.687	1.566	1.946
	(BR,4-7-1)	750	0.815	1.171	1.455	0.728	1.457	1.808
	(BR,4-7-1)	1000	0.816	1.170	1.455	0.727	1.458	1.808
M3	(BR,4-10-1)	250	0.790	1.248	1.553	0.742	1.379	1.773
	(BR,4-10-1)	500	0.791	1.242	1.547	0.739	1.392	1.782
	(BR,4-10-1)	750	0.795	1.231	1.535	0.741	1.378	1.773
	(BR,4-10-1)	1000	0.802	1.220	1.506	0.733	1.420	1.789

R^2 , MAE ve RMSE'nin değerleri eğitimde sırasıyla 0.76-0.88, 0.88-1.34 (mm) ve 1.13-1.65 (mm), testte ise 0.49-0.788, 1.19-2.11 (mm) ve 1.58-2.19 (mm) arasında değişmiştir. Modellerin tahmin yeteneğinin belirlenmesinde kullanılan istatistiksel yöntem sonuçları eğitim başarısının, test başarısından daha yüksek olduğunu göstermektedir. YSA eğitiminde kullanılan değerler ile eğitilmiş YSA'nın tahmin değerleri arasında istatistiksel sonuçları yüksek çıkmış ancak YSA'nın tahmin değerleri ile eğitimde kullanılmayan %30'luk değer arasında istatistiksel sonuçları düşük çıkmıştır. Bu sonuçlar, YSA'nın bu

çalışmada verilen modeliyle yeni değerler üzerinden tahmin yapıldığında tahmin yeteneğinin düştüğü tespit edilmiştir.

Eğitimde en başarı modelde (M2(LM,4-7-1) ve 250) R², MEA ve RMSE sırasıyla 0.86, 0.97 ve 1.254 olarak elde edilmiştir. Ancak testte en başarı modelde (M2(LM,4-7-1) ve 500) R², MEA ve RMSE ise sırasıyla 0.79, 1.195 ve 1.579 olarak elde edilmiştir. LM,4-7-1 ve 500 modeline göre belirleme katsayısı bağımlı değişken, bağımsız değişkeni %79 oranında temsil etmektedir. MAE ve RMSE istatistiğine göre YSA ile tahmin edilen değerler (TEp) ile ölçülen değerler (ÖEp) arasındaki hata sırasıyla 1.195 mm ve 1.579 mm olarak belirlemiştir.

Ölçülen Pan buharlaşma değerleri ile M2 (LM,4-7-1 ve 500) modeli ile tahmin edilen Pan değerleri arasındaki eşitlik Şekil 4'de verilmiştir. Bu iki değer arasında linear bir dağılım vardır. Bu iki değer arasında belirleme katsayı R² 0.79'dir. Bu hataların kabul edilebilir düzeyde olduğu söylenebilir.



Şekil 4. Ölçülen pan buharlaşma değerleri ile tahmin edilen pan değerleri arasındaki ilişki.

Sonuç

Bu çalışmada, A sınıfı buharlaşma kabından olan buharlaşmanın (Ep) rüzgar hızı, solar radyasyon, sıcaklık ve oransal nem değerlerini kullanarak yapay sinir ağı (YSA)'da oluşturulan modeller test edilmiştir. Bu modellerden eğitimde 250 tekrarlama ile en başarı model M2(LM,4-7-1) olduğu, bunun R², MAE ve RMSE istatistiksel sonuçlarının sırasıyla 0.86, 0.97 ve 1.254 olarak elde edilmiştir. Ancak bu modellerden testte 500 tekrarlama ile en başarı model M2(LM,4-7-1) olduğu, bunun R², MAE ve RMSE istatistiksel sonuçlarının sırasıyla 0.79, 1.195 ve 1.579 olarak elde edilmiştir. LM,4-7-1 ve 500 modeline göre belirleme katsayısı bağımlı değişken, bağımsız değişkeni %79 oranında temsil etmektedir. MAE ve RMSE istatistiğine göre YSA ile tahmin edilen değerler (TEp) ile ölçülen değerler (ÖEp) arasındaki hata sırasıyla 1.195 mm ve 1.579 mm olarak belirlemiştir. Bu hataların kabul edilebilir düzeyde olduğu söylenebilir.

Kaynaklar

- Allen R. G., Pereira L.S., Raes D. and Smith. M. (1998). Crop evapotranspiration-Guidelines for computing crop water requirements-FAO Irri. and Drainage Paper 56. FAO, Rome.
- Burgess, M.D. and Hanson, C. L. (1981). Automatic Class-A pan-filling system. *Journal of Hydrology* 50:389- 392.
- Burn, D. H., and Hesch, N.M. (2007). Trends in evaporation for the Canadian Prairies. *Journal of Hydrology* 336: 61-73.
- Chin, D. A. and Zhao, S. (1995). Evaluation of evaporationpan networks. *Journal of Irrigation and Drainage Engineering* 121:338-346.
- Chung, C.H., Chiang, Y.M. and Chang, F.J. (2012). A Spatial Neural Fuzzy Network for Estimating Pan Evaporation at Ungauged Sites. *Hydrology and Earth System Sciences*, 16. 255-266.
- Doorenbos, J. and Pruitt, W.O. (1977). Crop water requirements. FAO Irrigation Drainage Paper No. 24, FAO, Rome, Italy.
- Doğan, E. ve Işık, S. (2005). Sapanca Gölü Günlük Buharlaşma Miktarının Radyal Temelli Yapay Sinir Ağı Modeli Kullanılarak Tahmin Edilmesi. *Bilim Modern Yöntemler Sempozyumu*, s. 807-814. Kasım 16-18. Kocaeli.
- Ertek A, Şensoy S, Gedik, I. and Küçükymuk, C. (2006). Irrigation scheduling based on pan evaporation values for cucumber (*Cucumis sativus* L.) grown under field conditions. *Agricultural water management*, 81:159-172.

- Ertek, A. (2011). Importance of pan evaporation for irrigation scheduling and proper use of crop-pan coefficient (Kcp), crop coefficient (Kc) and pan coefficient (Kp). *African Journal of Agricultural Research*, 6:6706-6718.
- Fomby, T. (2008). Artificial neural networks (ANNs) Department of Economics Southern Methodist University. <http://faculty.smu.edu/efomby/eco5385/lecture/ANNs.pdf> (19.06.2013)
- Gençoğlan, C., Gençoğlan, S., Nikpeyma, Y. and Ucak, A. B. (2019). Determination of water-yield relationship of comice pear (*Pyrus communis* L.) Variety irrigated by the irrigation automation system (IAS) based on programmable logic controller (PLC). *Fresenius Environmental Bulletin*, 28:2433-2441.
- Gençoğlan, C., Gençoğlan, S. and Usta, S. (2023). Measurement of water depth in a class pan using ultrasonic transducer and programmable logic control (PLC). *Journal of Tekirdag Agricultural Faculty*, 20(2): 343-352.
- Hatfield, J.L. (1990). Methods of estimating evapotranspiration p. 435-474. In B.A. Stewart and D.R. Nielsen (Ed). *Irrigation of Agricultural Crops. Agronomy. American Society of Agronomy, Inc. Publishers. Madison, Wisconsin USA.*
- Inneci, T. and Badem, H. (2023). Detection of Corneal Ulcer Using a Genetic Algorithm-Based Image Selection and Residual Neural Network. *Bioengineering*, 10(6), 639.
- Hebb, D. (1949). *The Organization of Behavior*. Wiley. NewYork.
- Jang, J.S. (1993). ANFIS: Adaptive-network-based fuzzy inference system. *IEEE Trans. Syst. Man. Cybern*, 2: 665–685.
- LeCun, Y., Bengio, Y. and Hinton, G. (2015). Deep learning. *nature*, 521(7553), 436-444.
- Lewis, C.D. (1982). *Industrial and business forecasting methods: A practical guide to exponential smoothing and curve fitting*. Butterworths Scientific. ISBN: 978-0-408-00559-3, London, England, 144s.
- Kişi, O. (2006). Daily pan evaporation modelling using a neuro-fuzzy computing technique, *J. Hydrol.*, 329: 636–646.
- Kurucan, M., Özbaltan, M., Yetgin, Z. and Alkaya, A. (2024). Applications of artificial neural network based battery management systems: A literature review. *Renewable and Sustainable Energy Reviews*, 192, 114262.
- Leverington, D. (2009). *A Basic Introduction to Feedforward Backpropagation Neural Networks*. http://www.webpages.ttu.edu/dleverin/neural_network/neural_networks.html (13.06.2013).
- Matlab Guide (2024). *Train Regression Models in Regression Learner App*, Link: <https://www.mathworks.com/help/stats/train-regression-models-in-regression-learner-app.html> Erişim Tarihi: Kasım 2024
- McCullogh, W.S. and Pitts, W.A. (1943). A logical calculus of the ideas immanent in nervous activity. *Bull. Math. Biophysics*. Vol. 5: 115-133 p.
- Montesinos López, O. A., Montesinos López, A. and Crossa, J. (2022). Fundamentals of artificial neural networks and deep learning. In *Multivariate statistical machine learning methods for genomic prediction* (pp. 379-425). Cham: Springer International Publishing.
- Öztemel, E. 2003. *Yapay Sinir Ağları*, (2. Baskı 2006) ISBN: 975-67-97-39-8, Papatya Yayıncılık, İstanbul.
- Sudheer, P.K., Gosain, A.K., Mohana, R.D. and Saheb, S.M. (2002). Modeling evaporation using an artificial neural network algorithm. *hydrological process*. 16:3189- 3202.
- Usta, S., Gençoğlan, C. and Gençoğlan, S. (2022). Estimation of Daily Average Global Solar Radiation with Nonlinear Regression Models Developed Using Some Meteorological and Geographical Parameters. *Dicle Üniversitesi Mühendislik Fakültesi Mühendislik Dergisi*, 13(3), 589-597.
- Terzi, Ö. ve Keskin, E.M. (2005). Yapay sinir ağları yaklaşımı kullanarak günlük tava buharlaşmanın tayini. *YMO Teknik Dergi*. 3683-3693.
- Villarreal, M. R. (2007). Complete Neuron Cell Diagram en.svg, (LadyofHats) Wikipedia, the free encyclopedia. http://en.wikipedia.org/wiki/File:Complete_neuron_cell_diagram_en.svg.
- Wiegrebe, S., Kopper, P., Sonabend, R., Bischl, B. and Bender, A. (2024). Deep learning for survival analysis: a review. *Artificial Intelligence Review*, 57(3), 65.
- Yahaya, O., Smart, B., Omoakhale, A.I. and Ehibor, O.G. (2018). Development and Calibration of Automated Class A Evaporimeter. *Hydrol Current Res*. 9: 304.
- Yıldırım, D., Cemek, B. ve Küçüktopcu, E. (2019). Bulanık Yapay Sinir Ağları ve Çok Katmanlı Yapay Sinir Ağları ile Günlük Buharlaşma Tahmini. *Toprak Su Dergisi*, 24-31.
- Yurtoğlu, H. (2005). *Yapay Sinir Ağları Metodolojisi ile Öngörü Modellemesi: Bazı Makroekonomik Değişkenler İçin Türkiye Örneği*, DPT – Uzmanlık Tezleri, Yayın No: Dpt: 2683, Ekonomik Modeller ve Stratejik Araştırmalar Genel Müdürlüğü.