

Antalya İli Meteorolojik Verileri Yardımıyla Hava Sıcaklığının Yapay Sinir Ağları Metodu ile Tahmini

Estimation of Air Temperature by Artificial Neural Networks with Meteorological Data for Antalya Province

Kazım KUMAŞ^{1,a}, Mustafa AYAN^{1,b}, Ali Özhan AKYÜZ^{*2,c}, Afşin GÜNGÖR^{3,d}

¹Burdur Mehmet Akif Ersoy Üniversitesi, Bucak Emin Gülmez TBMYO, Elektrik ve Enerji Bölümü, 15300, Burdur

²Burdur Mehmet Akif Ersoy Üniversitesi, Bucak Emin Gülmez TBMYO, Elektronik ve Otomasyon Bölümü, 15300, Burdur

³Burdur Mehmet Akif Ersoy Üniversitesi, Teknoloji Fakültesi, 15300, Burdur

• Geliş tarihi / Received: 10.01.2019 • Düzeltilerek geliş tarihi / Received in revised form: 23.10.2019 • Kabul tarihi / Accepted: 28.10.2019

Öz

Atmosferin gelecekteki durumu hava tahminleri yoluyla belirlenir. Küresel ısınma ve iklim değişiklikleri nedeniyle hava koşullarının değişiklik göstermesi hava tahmini doğruluğunun önemini arttırmaktadır. Hava sıcaklığı, tarım başta olmak üzere sanayi ve benzeri birçok faaliyetin belirlenmesinde önemli rol oynamaktadır. Bitkilerin büyüme ve gelişmeleri için belirli bir sıcaklık değerine ihtiyaç vardır. Sıcaklığın yüksek olduğu ve değişkenlik gösterdiği durumda bitkiler olumsuz etkilenmektedir. Bu sebeplerden dolayı Akdeniz ikliminin görüldüğü ülkelerde ve seracılığın faaliyetlerinin yoğun olduğu bölgelerde hava sıcaklığı tahmini önemli bir hal almıştır. Son yıllarda geleceğe yönelik hava tahminleri ve araştırmaların sayısı oldukça artmıştır. Bu çalışmada Antalya'ya ait 2000-2016 yılları arasında ölçülen gerçek aylık ortalama buhar basıncı, aylık ortalama nisbi nem ilgili ay ve yıl verileri kullanılarak yapay sinir ağları metodu ile ortalama hava sıcaklığı tahmin edilmiştir. Yapay sinir ağı modeli performansı istatistiksel tekniklerle karşılaştırılmıştır. Sonuç olarak yapay sinir ağı modelindeki tahmin değerlerinin gerçek ortalama hava sıcaklığı değerleri ile uyumlu olduğu gözlemlenmiştir.

Anahtar kelimeler: Hava Sıcaklığı, Meteorolojik Veri, Tahmin Yöntemi, Yapay Sinir Ağları

Abstract

The future state of the atmosphere is determined by weather forecasts. The change in weather conditions due to global warming and climate changes increases the importance of forecasting accuracy. Air temperature plays an important role in the determination of many activities such as agriculture, industry and so on. A certain temperature value is needed for the growth and development of plants. Plants are adversely affected when the temperature is high and varies. For these reasons, air temperature estimation has become important in countries with Mediterranean climate and in areas where greenhouse activities are intense. In recent years, the number of future weather forecasts and research has increased considerably. In this study, the average monthly air pressure was estimated by using artificial neural network method by using real monthly average vapor pressure, monthly average relative humidity, related month and year data of Antalya between 2000-2016. The artificial neural network model performance has been compared with statistical techniques. As a result, it was observed that the estimated values in the artificial neural network model have been consistent with the actual average air temperature values.

Keywords: Air Temperature, Meteorological Data, Estimation Method, Artificial Neural Networks

*c Ali Özhan AKYÜZ; aakyuz@mehmetakif.edu.tr, Tel: (0248) 325 99 00, orcid.org/0000-0001-9265-7293

^a orcid.org/0000-0002-2348-4664

^b orcid.org/0000-0001-6780-0625

^d orcid.org/0000-0002-4245-7741

1. Giriş

Hava tahmini birçok alan için önemlidir. Bu alanlardan bazıları tarım, ulaşım, havayolu taşımacılığı olarak sıralanabilir. Anlık hava durumlarının rapor edilmesi kolaydır ancak geleceğe yönelik hava durumlarının tahmini, analizi oldukça zordur ve önemlidir. Tarım, hava ve yağışlara endeksli olan temel alanlardan biri olup zarara uğrayan alanlar gittikçe azalmaktadır. Hava durumu raporu kullanıcıların bilgilendirilmesi içindir. Bu sebeple, hava durumu tahmininin en az hata ile belirlenmesi kullanıcılar için yararlı olacaktır. Geleceğe yönelik hava tahminleri için birçok yöntem bulunmaktadır. Ancak en iyi sonuç, en uygun yöntemin kullanılması ile olacaktır (Sankari ve Valarmathi, 2017).

Sıcaklık, bitkilerin büyüme ve gelişmeleri için oldukça etkilidir. Her bitkinin yetişmesi için optimum sıcaklık değerine ihtiyaç duyulmaktadır. Yüksek sıcaklıktan bitkiler etkilenmektedir. Bu amaçla ilk kez ABD’de sığağa dayanaklı bölge haritaları çalışmaları Amerikan Bahçe Bitkileri Derneğinin 1974-1995 yılları ait 4745 meteoroloji ölçüm merkezinden aldığı veriler kullanılarak başlanmıştır (Peşkirioğlu vd., 2016).

Seralarda ürün yetiştirme sürecinde yetiştirilecek olan bitkiler için gerekli olan ışık, nem, sıcaklık vb. gibi çevre denetimini etkileyen unsurların kontrolü sağlanabilir. Seralarda yetişen bitkiler büyüme sırasında farklı sıcaklıklara gereksinim duymaktadır. Sıcaklık değerlerinin değişkenlik göstermesi, bitkinin verimini ve kalitesini etkilemektedir. Özellikle Akdeniz iklimine sahip bölgelerde yaz aylarında sıcaklığın yüksek değerlere ulaşması sera ürünlerinin veriminin ve kalitesinin düşmesine yol açmaktadır. Sıcaklığın kontrolünün sağlanmasında havalandırma, soğutma gibi yöntemler kullanılmaktadır. Kullanılan bu yöntemlerin yeterince etkili olmadığı ve yanlış kullanımlara yol açtığı bilinmektedir (Boyacı vd., 2017). Bu açıdan değerlendirildiğinde hava sıcaklığı tahmininin seralarda yetiştiricilik yapan kullanıcıların önceden gerekli önlemleri almasına yardımcı olacaktır.

Hava sıcaklığını tahmin etmek amacıyla çeşitli yöntemler kullanılır. Yapay sinir ağları (YSA) ve Anfis bu yöntemlerden bazılarıdır. Hayati ve Mohebi yaptıkları çalışmada, İran’ın batısındaki Kermanshah kenti sıcaklık tahmininde çok katmanlı algılayıcıya (Multi-Layered Perceptron) dayanan yapay sinir ağları üzerinde çalışmışlardır.

Eğitim ve test aşamasında 1996-2006 yıllarına ait meteorolojik verileri kullanmışlardır. Sonuç olarak ağın minimum hata verdiği ve modelin kısa süreli sıcaklık tahminleri için uygun bir yöntem olduğu belirlenmiştir. (Hayati ve Mohebi, 2007). Dombayci ve Gölcü yaptığı çalışmada Denizli günlük ortalama sıcaklığının tahmini için bir YSA modeli oluşturmuştur. Çalışmada Devlet Meteoroloji Müdürlüğü’nün 2003-2005 yılları arasındaki verileri eğitim verisi için, 2006 yılına ait verileri ise test verisi için kullanılmıştır. Oluşturulan modelde farklı algoritmalar ve nöron sayıları denenmiştir. Sonuç olarak ağın korelasyon (R^2) ve Root Mean Squared Error (RMSE) değerlerini tespit ederek karşılaştırmışlardır. YSA yaklaşımının sıcaklık tahmininde güvenilir bir yöntem olduğu vurgulanmıştır (Dombayci ve Gölcü, 2009). Bilgili ve Şahin yaptıkları çalışmada, Türkiye’nin herhangi bir noktasındaki ölçüm noktası verilerine göre uzun süreli aylık sıcaklık ve yağış miktarı tahmini için bir YSA modeli geliştirmişlerdir. Devlet Meteoroloji Müdürlüğü’nün 1975-2006 yılları arasındaki 59 istasyon verisini modelin eğitimi için, 17 istasyon verisini ise modelin testi için kullanmışlardır. Oluşturdukları modelin giriş parametreleri enlem, boylam, yükseklik ve zaman; çıkış ise uzun vadeli hava sıcaklığı ve yağış miktarıdır. YSA modeli sonuçlarını gerçek değerler ile karşılaştırmış ve modelde oluşan hataların kabul edilebilir düzeyde olduğunu ifade etmişlerdir (Bilgili ve Şahin, 2009). İbrikçi ve Soylu yaptıkları çalışmada, Adana hava sıcaklığı meteorolojik parametrelere göre tahmin etmişlerdir. Giriş parametreleri rüzgar, atmosferik basınç ve bağıl nemden oluşmakta, sıcaklık ise çıkış parametresini oluşturmaktadır. Çalışmada ortalama karesel hata (MSE) ve ortalama mutlak yüzde hata (MAPE) istatistiksel yöntemleri ile modelin verimliliği karşılaştırılmıştır (İbrikçi ve Soylu, 2014).

2016-2019 yılları arasında özellikle sonbahar ve kış aylarında Antalya’da ani hava sıcaklığı değişimleri yaşanmıştır. Bu değişimler fırtına, hortum gibi şiddetli meteorolojik olaylara neden olmuştur. Bu tür hava olaylarının sera işletmelerini olumsuz yönde etkileyeceği açıktır. Bu nedenle Antalya’da hava sıcaklığının seracılık faaliyetleri açısından bilimsel yöntemlerle tahmini önem arz etmektedir. Literatür incelendiğinde Antalya hava sıcaklığı tahmini için sadece Işık ve İnallı’nın çalışmasına rastlanmıştır. Işık ve İnallı 2000-2010 yılları arasındaki meteorolojik verileri kullanarak YSA metodu ile aylık ortalama güneş ışınımı, şiddeti, nispi nem ve sıcaklık değerlerini tahmin etmişlerdir. Kullandıkları geriye yayımlı çok katmanlı YSA modelinde güneşlenme süresi,

ortalama hava basıncı, açık gün sayısı, bulutluluk, buharlaşma ve aylık toprak üstü minimum sıcaklık girdi değerleri olarak alınmıştır.

Orta katmandaki nöron sayısı, giriş sayısı, öğrenme katsayısı gibi parametreler değiştirilerek modelin performansı incelenmiştir. (Işık ve İnallı, 2011) Bu çalışmada, Işık ve İnallı'nın çalışmasından farklı olarak Antalya iline ait 2000-2016 yılları arasında ölçülmüş aylık ortalama nisbi nem, aylık ortalama buhar basıncı, ilgili ay ve yıl verileri kullanılarak aylık ortalama hava sıcaklığı değerleri MATLAB Neural Network Toolbox 2014b kullanılarak YSA metodu ile tahmin edilmiştir.

2. Materyal ve Metot

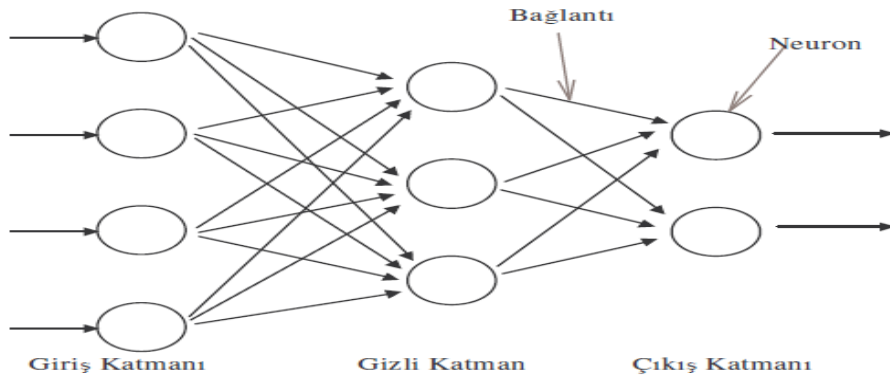
2.1. Yapay Sinir Ağları

YSA yapay zekâ yöntemlerinden biridir. En basit şekilde ifade edilecek olursa basit biyolojik sinir sistemlerin çalışma şekillerinin taklit edilerek oluşturulduğu matematiksel bir modeldir. YSA temel prensipleri arasında beynin öğrenerek yeni bilgiler elde etme, güçlü düşünme, problem çözme, tahmin etme vb. yeteneklerin kazandırılması gibi özellikler yer almaktadır. Doğrusal olsun ya da olmasın herhangi bir olayla

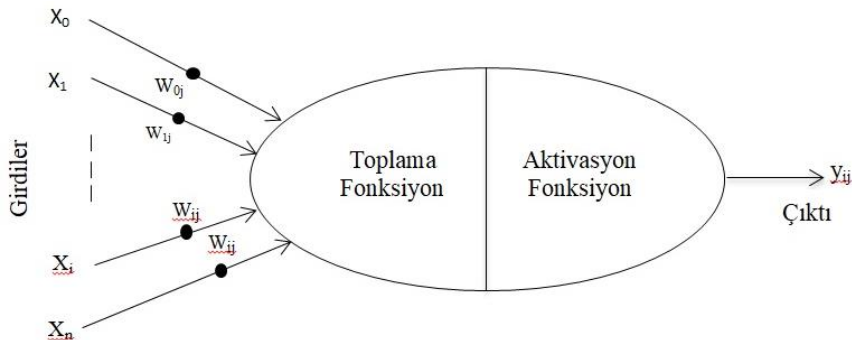
ilgili girdi ve çıktı arasında ilişkiyi, eldeki örneklerden öğrenerek önceki zamanlarda görülmemiş olayları, daha önceki örnekler vasıtasıyla ilişkilendirerek çözüm üretme gibi özellikleri nedeniyle YSA araştırmacılar tarafından ilgi görmektedir (Kaftan, 2010).

YSA eğitim ve test aşaması olmak üzere iki farklı şekilde çalışır. Öncelikle YSA'nın uygulanabilmesi için eğitilmesi gereklidir. YSA girdi, gizli ve çıktı olmak üzere üç ana tabakadan oluşmaktadır. Her bir tabaka nöronlardan oluşmaktadır. Nöronların çeşitli şekillerde birbirine bağlantıları ise ağı oluşturmaktadır. Nöronun işlevi giriş verilerinin her biri ağırlık değerleri ile çarparak elde edilen değerleri eşik (toplama fonksiyonu) değeri ile toplamak ve toplamı *sigmoid* veya *tanh* aktivasyon fonksiyonlarından geçirerek çıkışa verilmesini sağlamaktır. Genel olarak nöron çıkış sigmoid için (0-1), *tanh* için (-1,1) değerleri arasında olması beklenir (Şencan ve Çiçek Bezir, 2003). Şekil 1'de üç ana katmandan oluşan yapay sinir ağı bağlantıları verilmiştir (Ayvaz, 2012).

YSA Şekil 2'de verildiği gibi girdi (x_i), ağırlık (w_i), toplama ve aktivasyon fonksiyonu ile çıktı olmak üzere beş temel yapıdan oluşmaktadır (Aslay ve Özen, 2012).



Şekil 1. Yapay sinir ağı bağlantıları




Şekil 2. Yapay sinir ağı hücresinin genel yapısı

Girdi tabakasından gelen bilgiler belli standartlar çerçevesinde işlenerek çıkış tabakasına iletilir. Ağın temel görevini gizli katman yapmakta ve gizli katman sayısı gerçekleştirilecek amaç doğrultusunda ağdan ağa değişkenlik göstermektedir. Çıkış tabakasında ise ara katmandan gelen bilgiler işlenir ve girdi katmanına sunulmuş olan girdilere göre üretilmesi gereken çıktı üretilir. Ağa sunulan her bir verinin çıkış sayısı kadar çıktı katmanında nöron bulunur. Çıkış katmanından üretilen değerler yapay sinir ağlarının probleme karşı oluşturduğu çıkış değerlerini oluşturmaktadır. Yapay sinir ağları yönteminin kullanıldığı bir problemin

modellenmesinde, problemin en iyi çözümü için kullanılacak gizli katman sayısı ile birlikte katmanlardaki işlem elemanı sayılarının belirlenmesi oldukça önemlidir (Şahan ve Okur, 2016).

Yapılan çalışmada en iyi sonucun elde edilebilmesi için yapay sinir ağı metodunda çeşitli algoritma ile nöron sayıları kullanılmıştır. Çözüm mimarisi, 1000 iterasyon sonunda Şekil 3'de gösterilen tek tabaka ve on nörona sahip ileri beslemeli YSA modelinde elde edilmiştir.



Şekil 3. Uygulamada kullanılan YSA mimarisi

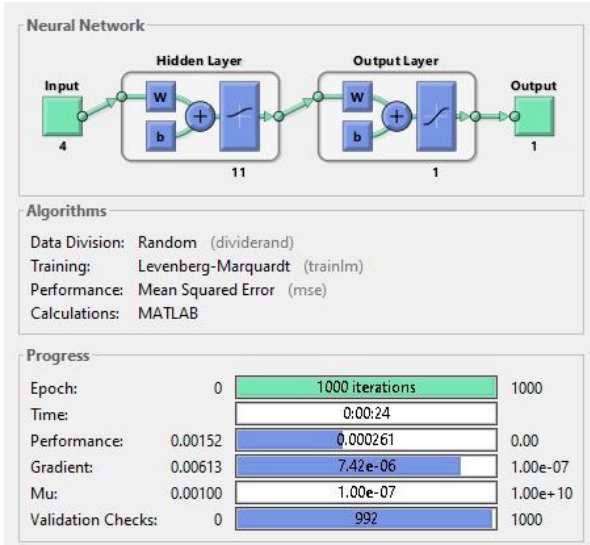
YSA'nın eğitimi için geriye yayılma algoritmasının *Levenberg Marquardt (LM)* ve *Logistic Sigmoid aktivasyon fonksiyonu* ve ağ tipi olarak ise kullanımının kolay olması, yakınsama hızıyla doğrusal ve doğrusal olmayan modellerdeki tahmininin iyi olması nedeniyle ileri doğru beslemeli geri yayınlı (*Feed-Forward BackProp*) seçilmiştir. Ağ performans fonksiyonunun değerlendirilmesinde ise ortalama karesel hata (*MSE*) kullanılmıştır. YSA modelinin tasarımı ile eğitiminde Şekil 4'de verilen Matlab'ın ara yüzü nntool kullanılmıştır. Verilerin eğitiminde, gizli katmandaki 3 ile 12 arasında değişen nöron sayısı kullanılmıştır. YSA modelinde girdi, çıktı nöron sayıları belirlenmiş ve daha sonra bağımlı ve bağımsız değişkenlerin sistemde kullanılması için normalize ederek değerler 0-1 aralığına getirilmiştir.

Türkiye Meteoroloji Genel Müdürlüğünden temin edilen verilerin %70 eğitim, %15 doğrulama ve %15'i ise test için kullanılmıştır. Verilerin

programa aktarılmasından sonrasındaki önemli aşamalarından biri de ağın eğitilmesidir. Bu aşamada veriler ağa sunularak ağ öğretilmiştir. YSA modelinin eğitiminde öğrenme katsayısı olarak 0.01, moment katsayısı ise 0.4 alınmıştır. İleri beslemeli YSA modelinin eğitimi aşamasında Antalya iline ait 2000-2014 yılları arasındaki aylık ortalama nisbi nem, aylık ortalama buhar basıncı, ilgili ay ve yıl, giriş parametresi olarak kullanılmıştır. YSA modelinin eğitim sürecindeki çıkış parametresi olarak 2000-2014 yılları için ortalama hava sıcaklığı alınmıştır. Buna göre 2015-2016 için ortalama nisbi nem, ortalama buhar basıncı, ilgili ay ve yıl verileri ışığında 2015-2016 yıllarına ait ortalama hava sıcaklığı tahmin edilmiştir.

YSA modellerinin iyi çalışıp çalışmadığı, gerçek değerler ile modelin oluşturduğu çıktı değerleri arasındaki sapma miktarına bağlıdır. Sapma miktarlarının belirlenmesinde genel olarak RMSE istatistiksel hata miktarı (root-mean-squared), R^2

(mutlak değişim yüzdesi), cov (değişim katsayısı) değerleri kullanılır (Köksal, 2011). İstatistiksel hata miktarı aşağıda belirtilen eşitlik 1,2 ve 3'ten hesaplanır (Şencan ve Kalogirou, 2005).



Şekil 4. Matlab nntool arayüzü ve eğitim verileri

$$RMSE = \sqrt{\frac{\sum_{m=1}^n (y_{p,m} - t_{m,m})^2}{n}} \quad (1)$$

$$R^2 = 1 - \frac{\sum_{m=1}^n (t_{m,m} - y_{p,m})^2}{\sum_{m=1}^n (t_{m,m} - \bar{t}_{m,m})^2} \quad (2)$$

$$cov = \frac{RMS}{|\bar{t}_{m,m}|} 100 \quad (3)$$

Eşitliklerde belirtilen $y_{p,m}$ tahmini değeri, $t_{m,m}$ ölçülen değeri, $\bar{t}_{m,m}$ gerçek değeri n ise veri sayısını ifade etmektedir.

Bir yapay sinir ağı modelinin performans değeri, RMS ve cov değerinin düşük, R^2 değerinin ise 1'e ortalama karesel hatanın da 0'a yakın olmasına bağlıdır (Köksal, 2011)

3. Araştırma ve Bulgular

Antalya ili aylık ortalama sıcaklık değerleri yapay sinir ağı modeli ile tahmin edilmiştir. En iyi sonucun elde edilebilmesi için gizli tabakada farklı nöron sayıları denenmiş ve elde edilen RMS, Cov ve R^2 değerleri Tablo 1'de verilmiştir. Antalya iline ait aylık ortalama hava sıcaklığı değerleri için en iyi R^2 sonucu Levenberg Marquardt (TRAINLM-11) algoritmasından elde edilmiştir. Levenberg-Marquardt optimizasyon algoritması çok katmanlı yapay sinir ağlarının eğitiminde uygulanan Newton yönteminin basitleştirilmiş bir şeklidir. Algoritma, parametrelerin yenileme aşamalarını giriş değerleri için oluşturulan hata ve Jacobiyen matrisini kullanarak gerçekleştirir. Geri beslemeli Levenberg-Marquardt algoritmasında (TRAINLM), lineer olmayan gerçek değerli fonksiyonların karelerinin toplamı olarak çok değişkenli bir fonksiyonun minimumu bulunur. Algoritmanın her bir iterasyonunda performans fonksiyonu her zaman azaltılır.

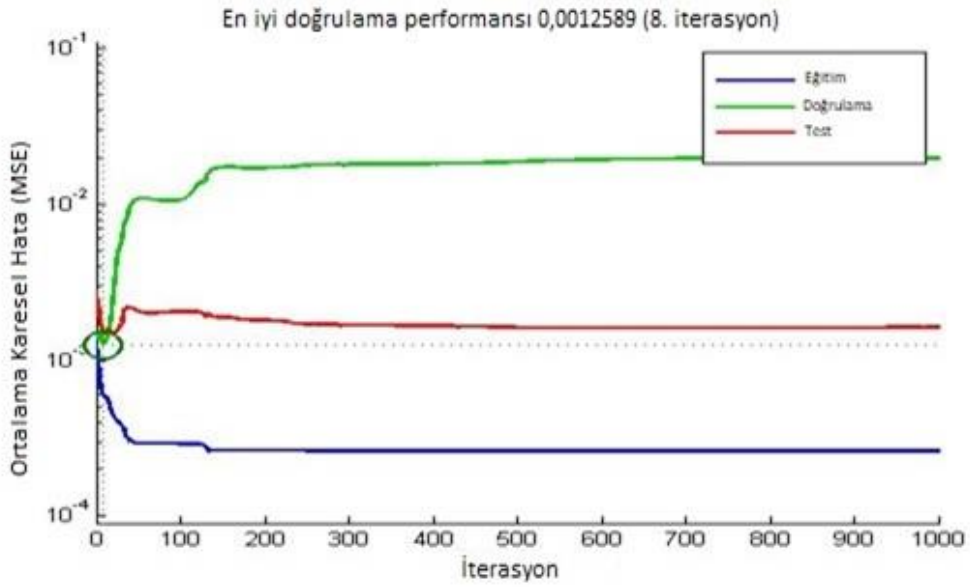
Tablo 1. Yapay sinir ağı ile tahmin edilen aylık ortalama hava sıcaklıklarının istatistiksel analizi

Algoritma-Neron	RMSE	Cov	R^2
LM-3	0.071298	0.143161	0.945875
LM-4	0.039527	0.079367	0.983313
LM-5	0.054317	0.109064	0.969093
LM-6	0.034420	0.069113	0.987392
LM-7	0.032372	0.065001	0.988860
LM-8	0.035902	0.072089	0.986244
LM-9	0.031286	0.062820	0.989504
LM-10	0.036587	0.073464	0.985837
LM-11	0.029111	0.058454	0.990972
LM-12	0.031073	0.062391	0.989713

Bu özellik TRAINLM'i orta büyüklükteki ağlar için en hızlı eğitim algoritması yapar. Ancak gradyan ve yaklaşık Hessian matrisinin hesaplanmasından kaynaklanan bellek ve hesaplama ek yükünün dezavantajına sahiptir.

Gerçekleştirilen eğitimde durma kriteri olarak 1000 iterasyon, 0 hata $1.00e-07$ gradient değeri ve 1000 doğrulama hata sayısı kullanılmıştır.

Eğitim 24 saniyede 1000 iterasyona ulaşarak durmuştur. Her bir iterasyonda ki eğitim, doğrulama ve test verilerine ait eğitim sırasındaki performanslarının değişimi Şekil 5'de verilmiştir. Modelin iterasyona bağlı performans grafiğine bakıldığında en düşük hata değeri 8. iterasyonda gerçekleşmiştir. Bu noktada MSE değeri ise 0.0012589 olarak bulunmuştur.




Şekil 5. Eğitim, doğrulama ve test verilerinin performans değişimi

Ağın durumunun gösterildiği bir diğer gradyan değeri, doğrulama hatası ve öğrenme oranı değişimleri gösterildiği grafik Şekil 6'da verilmiştir. Validation check değerinin 1000 iterasyonda 992 olduğu görülmektedir. Gerçek veriler ile tahmin verileri arasındaki farkın 8. iterasyondan sonra artmaya başlamasıyla döngü 1000 iterasyonda durdurulmuştur.

TRAINLM algoritmasında Newton yönteminin özelliği olan gradyan azalış özelliği kullanılır. Gradyan, fonksiyonların kısmi türevlerinin vektörüdür. Değişken sayısına bağlı olmaksızın gradyanın yönü, değişkenlerin hangi yönde değişmeleri halinde fonksiyonun artacağını gösterir. Gradyan yönünde ilerlenirse maksimuma, tersi yönde ilerlenirse minimuma yaklaşılr. Gradyan genel olarak hata oranında ne

kadar değişkenlik olduğunu göstermektedir. μ , sinir ağını eğitmek için kullanılan algoritma için kontrol parametresidir. Mu seçimi doğrudan hata yakınsamasını etkiler ve girdilerin korelasyon matrisinin maksimum özdeğerine bağlıdır. Eğitim sürecinde performansın gradyanının büyüklüğü ve doğrulama kontrolünün sayısı eğitimi sonlandırmak için kullanılır. Eğitim sürecinde minimuma ulaşıldığında gradyan çok küçük değer alır, gradyanın değeri önceden belirlenen bir değerden daha düşük değere ulaştığında eğitim durur. Doğrulama kontrollerinin sayısı doğrulama performansının düşmediği iterasyon sayısını gösterir. Doğrulama denetimi ile tamamlanan iterasyonun öncekine göre minimize olup olmadığı belirlenir ve belirlenen değere ulaştığında eğitim durur.




Şekil 6. Gradyan değeri, kontrol parametresi ve öğrenme oranı değişimleri

Yapılan modelin performansının gösterildiği regresyon (R) grafikleri Şekil 7’de verilmiştir. Şekil 7’de MSE göre eğitilen (Training) veriler $R = 0.99668$, test (Test) edilen $R=0.9909$ oldukça yüksek oranda eğitilip test edildiği görülmüştür. Yine grafiğe göre verilerin lineer çizgiler etrafında birikmesi bunun bir diğer göstergesidir. Eğitilen ve test edilen değerlerin doğrulama (Validation) $R=0.99363$ ile uyumlu olduğu göstermektedir. Tüm (All) $R=0.99548$ ile YSA ağ modelinin

yüzey pürüzlülük değerlerinin tahmininde oldukça yüksek güven aralığında kullanılabileceğini görülmektedir.

Sonuçlardan görüldüğü üzere tüm değerler 0.990’den büyüktür. Buradan özetle ağın öğrenme işlemi başarılı ile gerçekleşmiştir. Tüm veriler için değerlerin 1’e yakın olması YSA model çıkışı ile gerçek veriler arasında bir uyum olduğunu göstermektedir.



Şekil 7. Eğitim, doğrulama ve test kümelerine ait regresyon grafikleri

Antalya ilinin 2015-2016 yıllarına ait gerçek aylık ortalama hava sıcaklığı değerleri Meteoroloji Genel Müdürlüğünden alınmış ve YSA yöntemi ile tahmin edilen aylık ortalama hava sıcaklığı değerlerinin karşılaştırılması Tablo 2’de verilmiştir.

Şekil 8’de 2015-2016 yıllarına ait YSA’dan elde edilen aylık ortalama hava sıcaklığı tahminleri ile gerçek meteorolojik değerlerin karşılaştırılması verilmiştir. Grafiğe göre 2015 yılı 10. ve 11. aylar ile 2016 yılı 1, 11 ve 12. aylarda az da olsa sapmalar bulunmaktadır. Sonuç olarak test edilen gerçek değerlerin tahmin edilen değerler ile birbirine yakın olduğu görülmektedir.

Genel olarak belirtilirse, yapay sinir ağları yöntemi ile yapılan tahminde Logistic Sigmoid fonksiyonu kullanılmış ve en iyi sonuç LM11 algoritmasında elde edilmiştir. Ağın eğitimi 8.

iterasyonda tamamlanmış ve bu nokta için MSE değeri 0.0012589 olarak bulunmuştur. Kolerasyon (R) katsayıları sırasıyla eğitim, doğrulama, test ve tüm veriler için 0.996, 0.993, 0.990 ve 0.995 olarak bulunmuştur.

4. Sonuçlar


Bu çalışmada Türkiye Devlet Meteoroloji İşleri Genel Müdürlüğü’nden elde edilen Antalya ili 2000-2016 yılların ait aylık ortalama nisbi nem, aylık ortalama buhar basıncı, ilgili yıl ve ay verileri kullanılarak, YSA yöntemi ile aylık ortalama hava sıcaklığı tahmin edilmiştir. Yapay sinir ağları yöntemi ile tahmin edilen değerler gerçek meteorolojik değerler ile karşılaştırılmıştır. Yüksek hassasiyet ile sonuçların doğruluğu test edilmiş ve yapay sinir ağları yönteminin ortalama hava sıcaklığı tahmininde oldukça başarılı olduğu görülmüştür. Eğitim, test, doğrulama sırasında

gerçekleşen büyük regresyon değerleri ile küçük MSE değeri bunu desteklemektedir. Tüm değerlerin 1'e yakın olması YSA model çıkışı ile gerçek veriler arasında bir uyum olduğunu göstermektedir. Elde edilen istatistiksel analiz sonuçları, giriş bölümünde de verilen literatür çalışmalarının hepsiyle uyum içerisindedir. Özellikle Akdeniz iklimine sahip olan yaz

aylarında sıcaklığın yüksek değerlere ulaşması, buhar basıncı açığı gibi sebepler seralarda üretimi yapılan ürünlerin veriminin ve kalitesinin düşmesine yol açmaktadır. Bu açıdan değerlendirildiğinde yapılacak olan hava sıcaklığı tahmininin seralarda yetiştiricilik yapan firmaların önceden gerekli önlemleri almasında yardımcı olacaktır.

Tablo 2. Gerçek ve tahmin edilen aylık ortalama hava sıcaklık değerlerinin karşılaştırılması

Yıl	Ay	Gerçek Ortalama Hava Sıcaklığı (°C)	YSA Yöntemi ile Tahmin Edilen Ortalama Hava Sıcaklığı (°C)	Yıl	Ay	Gerçek Ortalama Hava Sıcaklığı (°C)	YSA Yöntemi ile Tahmin Edilen Ortalama Hava Sıcaklığı (°C)
2015	1	9.7	10.23009	2016	1	9.50	10.37986
2015	2	11.0	10.76558	2016	2	13.5	13.01202
2015	3	13.2	13.45850	2016	3	14.3	13.53719
2015	4	15.5	16.33532	2016	4	18.6	17.75314
2015	5	21.3	21.08182	2016	5	20.3	21.17976
2015	6	24.1	24.91968	2016	6	26.5	26.13384
2015	7	28.6	28.95301	2016	7	29.7	29.42177
2015	8	29.5	29.52410	2016	8	29.1	29.27760
2015	9	26.3	25.81485	2016	9	25.5	25.91478
2015	10	21.5	20.97218	2016	10	21.8	22.34395
2015	11	16.3	15.21898	2016	11	15.4	17.78327
2015	12	11.0	10.96698	2016	12	9.30	11.64295



Şekil 8. YSA ile tahmine edilen aylık ortalama sıcaklık verileri ile gerçek meteorolojik değerlerin karşılaştırılmalı grafiksel gösterimi

Kaynaklar

Aslay, F. ve Özen, Ü., 2013. Meteorolojik Parametreler Kullanılarak Yapay Sinir Ağları ile Toprak Sıcaklığını Tahmini. Politeknik Dergisi,16(4), 139-145.

Ayvaz, E., 2012. Yapay Sinir Ağları ve Paralel Akışlı Isı Eşanjörlerinde Uygulanması, Yüksek Lisans Tezi, Karadeniz Teknik Üniversitesi Fen Bilimleri Enstitüsü, Trabzon.

- Bilgili, M. ve Sahin, B., 2009. Prediction of long-term monthly temperature and rainfall in Turkey. *Energy Sources, Part A: Recovery, Utilization, and Environmental Effects*, 32(1), 60-71.
- Boyacı, S., Akyüz, A., Üstün, S., Baytorun, A. F. ve Güğercin, Ö., 2017. Seralarda Yüksek Sıcaklıkların Azaltılmasında Kullanılan Yöntemler. *Turkish Journal of Agricultural Research*, 4(1), 89-95.
- Dombayci, Ö. A. ve Gölcü, M., 2009. Daily means ambient temperature prediction using artificial neural network method: A case study of Turkey. *Renewable Energy*, 34(4), 1158-1161.
- Hayati, M. ve Mohebi, Z., 2007. Application of Artificial Neural Networks for Temperature Forecasting. *World Academy of Science, Engineering and Technology. International Journal of Electrical and Computer Engineering*, 1(4), 654-658.
- Işık, E. ve İnallı, M., 2011. İklim Sistemlerinin Projelendirilmesini Etkileyen Meteorolojik Verilerin Akıllı Sistemlerle Tahmini ve Örnek Uygulama. 18-20 Kasım 2011, Antalya.
- İbrikçi, T. ve Soylu, A., 2014. An Application of Neural Networks For Weather Temperature Forecasting. EE-588 Advanced Topics In Neural Network, Cukurova University Department of Electrical&Electronics Engineering, The Project Report, Adana, 20p.
- Kaftan, İ., 2010. Batı Türkiye Gravite ve Deprem Katalog Verilerinin Yapay Sinir Ağları ile Değerlendirilmesi. Doktora Tezi, Dokuz Eylül Üniversitesi, Fen Bilimleri Enstitüsü, İzmir.
- Köksal, E., 2011. Makina Elemanları Konstrüksiyonunda Çentik Faktörünün Yapay Sinir Ağları ile Hesaplanması, Yüksek Lisans Tezi, Gazi Üniversitesi, Fen Bilimleri Enstitüsü, Ankara.
- Peşkirioğlu, M., Özaydın, K. A., Özpınar, H., Nadaroğlu, Y., Dokuyucu, Ö., Aytaç Cankurtaran, G., Ünal, S. ve Şimşek, O., 2016. Bitkilerin Sıcağa ve Soğuğa Dayanıklılık Bölgelerinin Türkiye Ölçeğinde Coğrafi Bilgi Sistemleri ile Haritalanması. *Tarla Bitkileri Merkez Araştırma Enstitüsü Dergisi*, 25(1), 11-25.
- Sri Sankari G. ve Valarmathi, Dr.A., 2017. Weather Forecasting with Back Propagation of Neural Network using MATLAB. *International Journal of Scientific Research in Computer Science, Engineering and Information Technology*, 2(2), 2456-3307.
- Şahan, M. ve Okur, Y., 2016. Akdeniz Bölgesine Ait Meteorolojik Veriler Kullanılarak Yapay Sinir Ağları Yardımıyla Güneş Enerjisinin Tahmini. *SDU Journal of Science (E-Journal)*, 11(1), 61-71.
- Şencan, A. ve Çiçek Bezir, N., 2003. Ölçülebilen Meteorolojik Verilerle Güneş Radyasyonunun Yapay Sinir Ağları Metoduyla Tayini. TMMOB Makine Mühendisleri Odası Güneş Enerjisi Sistemleri Sempozyumu ve Sergisi, 20-21 Haziran 2003, Mersin, s. 235-239.
- Şencan, A. ve Kalogirou, S., A., 2005. A new approach using artificial neural networks for determination of the thermodynamic properties of fluid couples. *Energy Conversion and Management*, 46(15-16), 2405-2418.