

# Yapay Sinir Ağları Kullanılarak Sera Isıtma İhtiyacının Tahmini

**Bekir YELMEN, M. Tarık ÇAKIR\***

Makina Bölümü, Meslek Yüksekokulu, Aksaray Üniversitesi 68400 Aksaray

\* İnşaat ve Onarım Daire Başkanlığı, Sağlık Bakanlığı, 06590 Ankara

Geliş/Received : 18.07.2011, Kabul/Accepted : 04.10.2011

## ÖZET

Bu çalışmada, Mersin il ve ilçelerine ait seralar için enlem, boylam, yükseklik, aylar, ortalama sıcaklık verileri dikkate alınarak birim yüzey ve taban alanları için ısıtma gereksinimleri yapay sinir ağları (YSA) modeli kullanılarak belirlenmiştir. Yapay sinir ağları modelinde seralarda ısıtma ihtiyacı; enlem, boylam, yükseklik, aylar ve ortalama sıcaklık giriş katmanı olarak ve ısıtma ihtiyacı çıkış katmanı olarak kullanılmıştır. Mersin ili ve 7 ilçeye ait olan verilerden 6 ilçe eğitim verisi, Mersin merkez ve Tarsus ilçesi test verisi olarak yapay sinir ağları modelinde kullanılmıştır. Farklı ağ yapılarında Levenberg-Marquardt (LM) eğitim algoritması kullanılarak test ettirilen verilerden ortalama %99'un üzerinde tahmin ( $R^2$ ) değeri elde edilmiştir. Karesel hataların ortalama karakökü (RMSE) değeri test verileri için ortalama 0.0498 eğitim verileri için 0.0018 olarak bulunmuştur. Test verileri için ortalama mutlak hata (MAE) 0.0478, eğitim verileri için 0.0014 olarak bulunmuştur. Sonuç olarak; bu çalışmada yapay sinir ağları modeli kullanılarak seraların ısıtma ihtiyacının başarılı bir şekilde tahmin edilmesi sağlanmıştır.

**Anahtar Kelimeler:** Sera, Isıtma İhtiyacı, Yapay Sinir Ağları

## The Estimate for the Green House Heating Demand Using Artificial Neural Networks

### ABSTRACT

In this study by taking into account the latitude, longitude, height, months and mean temperature data of the city and districts of Mersin, the heating need for unit base and surface zone is determined. In the model of artificial neural nets the heating need for the green house which is longitude, latitude, height and means temperature data is used as entry layer and the need for heater need is used as exit layer. Of the data belonging to Mersin Province and 7 districts; 6 district education data, Mersin Centrum and Tarsus district are used as test data in artificial neural net model. The data has been tested by using Levenberg-Marquardt algorithm and an estimate ( $R^2$ ) of value from an average of %99 has been found. The average of quadric error square root value is 0.0498 in average and is 0.0018 for education data. The mean absolute error for test data is 0.0478 and 0.0014 for education data. In conclusion, this study focused on the successful estimate of green house heater need by using the model of artificial neural nets.

**Keywords:** Green house, heater need, artificial neural networks

### 1. GİRİŞ (INTRODUCTION)

Bugünkü tarım çalışmalarında daha rekabetçi bir çevreye adapte olunmalı ve sonuç olarak yeni akıllı teknolojiler kullanılmalıdır [1]. Seralarda bitkisel üretim yetiştiriciliği karlı ürün elde etmenin bir yoludur [2-4]. Bitki üretim sistemlerinde enerji tasarrufu ve daha az ham madde tüketimi ile daha yüksek miktarda hasat elde edilmesi istenir. Bu amaçla, tarımsal üretim yapanlar enerji ihtiyacını azaltmak için akıllı teknolojik sistemleri kullanmaları gerekmektedir [5-6].

Bugünkü koşullarda yapay sinir ağları (YSA) modeli kullanılarak seralarda ısıtma ihtiyacı tahmini yapılabilir. YSA, bir insanın düşünme ve gözlemleme yeteneklerini gerektiren problemlere yönelik çözümler üretebilmesi için insan beyninin ve dolayısıyla insanın sahip olduğu yaşayarak veya deneyerek öğrenme yete-

neğini taklit etmektedir. İnsanlarda öğrenme, sinir hücreleri (nöronlar) arasındaki sinaptik bağlantıların ayarlanması ile olur. Yani, doğumlarından itibaren yaşayarak öğrenme süreci içerisinde olduklarından, beyin sürekli bir gelişme göstermektedir. Tecrübelerin sayısı arttıkça sinaptik bağlantılar ayarlanır ve yeni bağlantılar oluşur. Bu sayede öğrenme gerçekleşir. Bu durum YSA için de geçerlidir. Öğrenme, eğitime yoluyla örnekler kullanarak olur. Gerçekleşen girdi ve çıktı verilerinin işlenmesiyle, yani eğitime algoritmasının bu verileri kullanarak, bağlantı ağırlıklarında bir yakınsama sağlanana kadar, tekrar tekrar ayarlanmasıyla olur [7].

YSA birçok basit sinir hücresinin bir araya gelmesinden oluştuğu için, çok tabakalı bir yapıya sahiptir. YSA' daki tabakalar, her bir tabakadaki hücreler ve bunların bir tabakadan diğerine bilgi ileten bağlantıları sanki bir bilgi ağı meydana getirir. Böyle bir ağda paralel tabakalar ve bunların içinde hücreler ve bunlar arasındaki ardışık bağlantıları sağlayan iletişim yolları bulunur.

\* Sorumlu Yazar (Corresponding Author)

e-posta: [mutlutar@gmail.com](mailto:mutlutar@gmail.com)

Digital Object Identifier (DOI) : 10.2339/2011.14.4, 235-241

Son yıllarda yapay sinir ağları (YSA) pek çok mühendislik uygulamalarında kullanıldığı gibi, sera çevre kontrol uygulamalarında da kullanılmıştır [8]. Bununla ilgili yapılan çalışmalarda ise Ehret D. ve ark (2008) ile Frausto H. ve ark (2004)'te yapmış oldukları çalışmada sera çevre koşulları ve bitki yetiştirme ortamları bazı büyüme periyotları göz önüne alınarak biberde ve domatestede kütükula çatlamasını tahmin etmede YSA kullanmışlardır [9-10]. Linker ve Seginer (2004) sera iç ortam sıcaklığının belirlenmesinde farklı YSA modellerini denemişlerdir [11]. Aynı şekilde, Ferreira ve ark (2002), su kültürü uygulamalı bir serada iç ortam sıcaklığını belirlemek için dış ortam sıcaklığı ve solar radyasyon ile iç ortam bağıl nem değerlerini girdi parametresi olarak seçmişlerdir [12].

Linker ve ark (1998) sıcak iklimlerde CO<sub>2</sub> zenginleştirme ihtiyacı ve havalandırma isteği arasında hassas bir dengenin kurulması için YSA'nın kullanılabilirliği üzerine çalışmışlardır. Küçük bir sera içinde iki dönem yaz aylarına ait veriler kullanılarak sinir ağlarında eğiterek serada buharlaşmayla soğutma etkisinin belirlenmesinin sinir ağları modeli ile yapılabileceğini göstermişlerdir [18].

Bu çalışmada, Mersin il ve ilçelerine ait seralar için birim taban ve yüzey alanı için ısıtma ihtiyacının tahmini yapay sinir ağları modeli ile yapılmıştır. İleri beslemeli geri yayınlı yapay sinir ağları modeli kullanılarak seraların ısıtma ihtiyacının tahmininin de iyi sonuçlar alınabileceği görülmüştür.

## 2. MATERYALVE METOT (MATERIAL AND METHOD)

Bu çalışmada Mersin il ve ilçelerine ait seralar için ısıtma ihtiyacının olduğu aylar (Ocak, Şubat, Mart, Nisan, Kasım ve Aralık) da birim taban alanına sahip plastik seralar için ısıtma ihtiyacı hesaplaması yapılmıştır. Isı tüketiminin hesaplanmasında dış sıcaklık ve güneş radyasyonu dikkate alınmıştır. Gün boyunca ısıtma ihtiyacı, güneş enerjisi ve ısıtma sistemlerinden karşılanmaktadır. Etkin ısı tüketimi ( $q_H$ ) aşağıdaki eşitlikle hesaplanmıştır [13].


$$q_H = \left(\frac{A_c}{A_g}\right) \times U \times (t_i - t_d) - q_{GI} \times D \times \eta \quad (1)$$

Eşitlikte;  $q_H$  etkin ısı tüketimini ( $W/m^2$ ),  $A_c$  sera örtü yüzey alanını ( $m^2$ ),  $A_g$  sera taban alanını ( $m^2$ ),  $U$  toplam ısı iletim katsayısını ( $W/m^2K$ ),  $t_i$  istenilen sera iç ortam sıcaklığını ( $^{\circ}C$ ),  $t_d$  dış ortam sıcaklığını ( $^{\circ}C$ ),  $q_{GI}$  güneş radyasyonu yoğunluğunu ( $W/m^2$ ),  $D$  güneş radyasyonu geçirgenlik oranını (0,6-0,7),  $\eta$  serada radyasyon enerjisinin ısı enerjisine çevirme faktörünü (0,5-0,7) ifade etmektedir. Isıtma ihtiyacının hesaplanmasında, dış sıcaklık olarak aylık ortalama sıcaklık ve sera içi sıcaklığı olarak da sera bitkilerinin çoğunun gereksinimlerini karşılayabildiği  $17^{\circ}C$  alınmıştır [14].

Çalışmada Mersin il ve ilçelerine ait seralar için ısıtma ihtiyacının olduğu aylar (Ocak, Şubat, Mart, Nisan, Kasım ve Aralık), enlem, boylam, yükseklik ve or-

talama sıcaklık verileri kullanılarak seraların birim alanı için ısıtma ihtiyacının tahmini yapay sinir ağları modeli kullanılarak tahmini yapılmıştır. Yapay sinir ağlarında toplam 48 veri kullanılmıştır. Farklı ağ yapılarında toplam verinin 36 tanesi eğitim verisi, 12 tanesi test verisi olarak kullanılmıştır.

Yapay sinir ağları modeli giriş katmanı, gizli katman ve çıkış katmanı olarak üç çoklu katman yapı-sından oluşmaktadır. Bu çalışmada tek katmanlı ve çift katmanlı yapay sinir ağı modeli oluşturularak seraların ısıtma ihtiyacı tahmin edilmiştir. Farklı ağ yapılarında gizli katmanda sinir sayısı 5-6 olarak alınmıştır. Şekil 1' de gösterilen bir yapay sinir ağı modelidir.  $N$  tane  $X_i$  girişinin ağırlıklı  $W_{ij}$  toplamını alarak bu toplam doğrusal olmayan bir  $f(.)$  fonksiyondan geçirerek bir  $Y_j$  çıktısı üretmektedir.



Şekil 1. Yapay sinir ağı modeli

Şekil 1' de verilen çok katmanlı bir ağ için, herhangi bir birimin giriş değeri  $x_i, i = 1, \dots, N$  vektörü ile ifade edilerek, kendisine diğer katmanlardan gelen (bir saklı katman veya bir giriş katmanından) değerlerin bir ağırlık değerleri  $w_{ij}, j = 1, \dots, v$ , ile çarpılmakta ve sonuçlar  $i$  indeksi boyunca toplanmakta ve gizli birimlerin giriş değerleri ( $v_j$ ) hesaplanmaktadır. Bu işlem için;

$$v_j = \sum_{i=1}^N x_i w_{ij} \quad (2)$$

$j = 1, \dots, N$  formülasyonu kullanılmaktadır. Burada  $v_j$ , (2)  $j$ nci gizli sinir hücresinin girdi değerini,  $w_{ij}$  ise  $i$ nci sinir hücresinden  $j$ nci sinir hücresine olan ara bağlantının ağırlık değerini göstermektedir. Birimin çıkışı ise bu ağırlıklı toplamın, doğrusal olmayan bir fonksiyondan geçirilmesiyle aşağıdaki gibi ifade edilir.

$$Y_j = f(v_j) \quad (3)$$

Her gizli sinir hücresi bir sigmoid etkinlik fonksiyonu kullanarak bir gizli nöron çıktısı  $Y_j$  oluşturur.  $v_j$  aşağıdaki formül kullanılarak hesaplanır.

$$Y_j = f(v_j) = \frac{1}{1 + \exp(-(v_j + \theta_j))} \quad (4)$$

$f(v_j)$ , (4)  $j$  nci gizli nöronun çıktı değeridir.  $\theta_j$  bias sabiti olarak ifade edilen başlangıç değeridir.  $Y_j$  bir sonraki katmanın girdisi olacaktır. Daha sonra çıktı katmanında,

$$IO_n = \sum_{j=1}^h w_{jn} Y_{jn} \quad (5)$$

$n = 1, \dots, m$  formülasyonu kullanarak çıkış düğümlerinin girdi değerleri hesaplanır,  $IO_n$  (5) çıkış katmanındaki nöronların girdi değeridir. Elde edilen bu değerler çıkış katmanının etkinlik fonksiyonundan geçirilerek  $O_n = f(IO_n)$  ağ çıkış değerleri hesaplanır. Bunların sonucunda ağırlık güncellemesi ve öğrenme süreci geri yayılım algoritması ile sağlanarak YSA' da kullanılan çeşitli geri yayılım algoritmaları "trainlm", "traingd", "traingdx" vs. olarak en çok bilinenlerdir. Geri yayılım algoritmasının amacı elde edilen karesel hatanın iterasyon(adım sayısı) ile en aza indirilmesini sağlamaktır. Bunun takibinde hata gradyanlarının ortalama karesel hata (MSE) ile elde edilmesiyle girdi değerlerine eşit şekilde dağıtılarak girdi ağırlıkları güncellenir ve bu süreç tekrar başlatılır. Ortalama karesel hata istenen değere ulaştığında veya belirlenen adım sayısına ulaşılan kadar bu işlemler tekrarlanır.

$$E = \frac{1}{2} \sum_j \sum_n (K_{jn} - O_{jn})^2 \quad (6)$$

formülasyonunda  $K_{jn}$  hedeflenen çıkış değerini,  $O_{jn}$  sinir ağının ürettiği çıkış değerini ifade etmektedir. Ağırlıkların güncellenmesi (7);

$$\Delta w_{jn} = -\eta \frac{\partial E}{\partial w_{jn}} \quad (7)$$

formülü ile en dik iniş yöntemiyle değiştirilerek hatanın en az seviyeye indirilmesi için çalışılır.  $\eta$  öğrenme oranıdır, eğer  $\eta$  değerinin küçük olması inişin çok yavaş olduğunu ifade eder.  $\eta$  nin büyük olduğu durumlarda da yüksek genlikli salınımlar gözlenebilir. Bu soruna getirilen çözümlerden birisi  $\alpha(w_{jn}^t - w_{jn}^{t-1})$  şeklinde bir terim eklemektir.  $\alpha$  momentum sabiti olarak isimlendirilir.

Çalışmada kullanılan veriler yapay sinir ağları modelinde tahmin yapılmasında çok iyi sonuçlar vermemiştir. Veriler, Eş.8 kullanılarak normalize edilmiştir. Veriler (0,1) değerleri aralığına getirilerek standartlaştırılmıştır. Standartlaştırılan veriler yapay sinir ağlarında kullanılarak seraların ısıtma ihtiyacının tahmin edilmesinde iyi sonuçların alındığı görülmüştür.

$$X_n = \frac{(X_{gerçek} - X_{min})}{X_{max} - X_{min}} \quad (8)$$

$X_n$  = Normalize edilen veri değeri

$X_{min}$  = Normalize olacak verinin min değeri

$X_{max}$  = Normalize olacak verinin max değeri

Bu çalışmada her bir model 36 adet eğitim veri seti ile eğitilmiş, 12 adet test veri seti ile test edilmiştir. Elde edilen modelin istatistiksel olarak doğruluğunu belirlemek için, Karesel Hataların Ortalamasının Karekökü (RMSE) ölçütü Eş. 9 kullanılarak hesaplanmıştır [15].

$$RMSE = \sqrt{\frac{\sum_{i=1}^N (y_i - y_i')^2}{N}} \quad (9)$$

$R^2$  eşitliğine göre;  $m$  test edilen verilerin sayısı,  $O_i$  yapay sinir ağında tahmin edilen veriler,  $y_i$  hesaplanan ısıtma miktarıdır [16].

$$R^2 = \frac{\left[ \sum_i^m (y_i - \bar{y})(O_i - \bar{O}) \right]^2}{\sum_{i=1}^m (y_i - \bar{y})^2 \sum (O_i - \bar{O})^2} \quad (10)$$

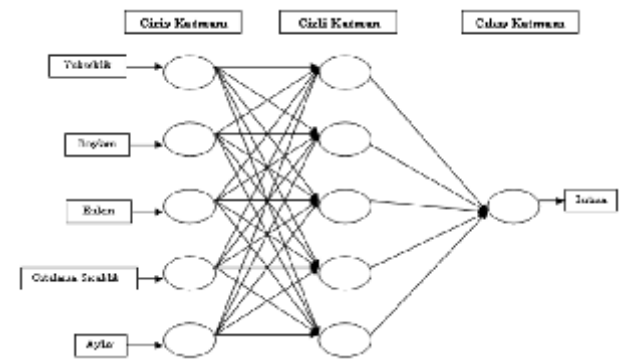
$\bar{y}$  hesaplanan ısıtma miktarı ( $y_i$ )' nin ortalaması ve  $\bar{O}$  yapay sinir ağında tahmin edilen ısıtma miktarlarının ( $O_i$ ) ortalama değerleridir. Bunların yanında ortalama mutlak hata (MAE) değerleri hesaplanmıştır [15-17].

$$MAE = \frac{1}{N} \sum_{i=1}^N |y_i - y_i'| \quad (11)$$

Bunlara ek olarak, tahmin edilen ısıtma ihtiyacının değerlendirilmesi için doğrusal regresyon modeli  $y = \alpha_1 x + \alpha_0$  uygulanmıştır. Burada;  $x$  bağımsız değişken (ısıtma miktarı);  $\alpha_0$  kesişim,  $\alpha_1$  eğimi ifade etmektedir [16].

### 3. BULGULAR VE TARTIŞMA (FINDINGS AND DISCUSSION)

Yapay sinir ağları modeli giriş katmanı, gizli katman ve çıkış katmanından oluşmaktadır. Bu çalışmada kullanılan yapay sinir ağları modeli Şekil 2 de gösterilmiştir.



Şekil 2. Yapay sinir ağı modelinde tahmini yapılan seraların ısıtma ihtiyacında kullanılan ağ yapısı.

Bu çalışmada Mersin il ve ilçelerine ait toplam 48 veri kullanılmıştır. Toplam verinin 36' ı eğitim verisi, 12' si test verisi olarak kullanılmıştır. İlk aşamada Mersin ili ve Tarsus ilçesine ait veriler test ettirilmiştir. Bu değerler Levenberg-Marquardt (LM) eğitim algoritması kullanılarak değerlendirilmiştir. Test verileri farklı ağ yapılarında test ettirilerek tahmin sonucunun en iyi olduğu ağ yapısı tercih edilmiştir. Kullanılan farklı ağ yapılarında Mersin iline ait ilçelerinin (Anamur, Bozyazı, Aydınçık, Silifke, Erdemli ve Mezitli) ısıtma gereksinimi tahmini yapılmıştır. Yapay sinir ağlarında test verisi olarak kullanılan Mersin ilinin ve Tarsus ilçesinin LM eğitim algoritmasında farklı ağ yapılarında deneme yoluyla tahmin edilen ısıtma ihtiyacı en iyi tahmin sonuçları ve istatistiksel performansları Çizelge 1' de verilmiştir. Test verilerinin tahmininde farklı iterasyon sayıları kullanılmıştır ve en iyi sonuç 300 iterasyon (adım) sayısında alınmıştır.

Çizelge 1. Test verileri için farklı ağ yapıları kullanılarak seraların ısıtma gereksinimlerinin tahmininde elde edilen en iyi sonuçlar ve istatistiksel değerlendirme.

	Ağ Yapısı			R <sup>2</sup>	RMSE	MAE	İterasyon Sayısı
Mersin	5*6*1	0.804	0.118	0.9979	0.077	0.070	300
Tarsus	5*5*1	0.778	0.047	0.9962	0.038	0.059	300

Mersin ilinin yapay sinir ağlarında tahmin edilen ısıtma değerlerinde LM eğitim algoritmasında tek katmanlı ve çift katmanlı ağ yapısı kullanılarak çıkış verisinin tahmini yapılmıştır. Tek katmanlı ve çift katmanlı ağ yapısında gizli katman olarak 5 ve 6 sinir sayısı kullanılmıştır.

Mersin ili seraları için yapay sinir ağlarında en iyi tahmin sonuçları, 6\*1 ağ yapısında 0.9979 tahmin (R<sup>2</sup>) değeri, 0.077 RMSE ve 0.070 MAE değeri elde edilmiştir.

Farklı ağ yapılarında eğitim verisi için 100 iterasyon (adım) sayısı kullanılarak tahmini yapılmıştır. Test verisi olarak kullanılan Tarsus ilçesi için 5\*1 ağ yapısında 0.9962' lik tahmin (R<sup>2</sup>) değeri, 0.038 RMSE değeri ve 0.059 MAE değeri elde edilmiştir.

Yapay sinir ağları modelinde Mersin ilçeleri (Anamur, Bozyazı, Aydınçık, Silifke, Erdemli ve Mezitli) eğitim verisi olarak kullanılmıştır. Eğitim verileri LM eğitim algoritmasında farklı ağ yapıları kullanılarak tahmini yapılmıştır. Eğitim verilerinin Çizelge 2'de gösterildiği gibi en iyi sonuçları ve istatistiksel değerlendirmeleri verilmiştir. Eğitim verileri için 100 iterasyon sayısında 5\*1, 5\*5\*1 ve 5\*6\*1 ağ yapılarında tahmin değeri (R<sup>2</sup>) 0.999 olarak elde edilmiştir. 6\*1 ağ yapısında R<sup>2</sup> değeri 0.998 olarak elde edilmiştir. 5\*1, 6\*1, 5\*5\*1 ve 5\*6\*1 ağ yapılarında RMSE ve MAE değerleri sırasıyla 0.0014, 0.0021, 0.0012, 0.0014 ve 0.0008, 0.0009, 0.0004, 0.0008 olarak elde edilmiştir.

Çalışmada test verisi olarak kullanılan Mersin ili ve Tarsus ilçesi için tahmin değerinin (R<sup>2</sup>) en iyi sonucunun alındığı ağ yapısında Şekil 3'te grafiksel olarak gösterilmiştir. Eğitim verileri olarak kullanılan Anamur, Bozyazı, Aydınçık, Silifke, Erdemli ve Mezitli ilçelerine ait değerler test ettirilerek Şekil 4'te grafiksel ola-

rak ifade edilmiştir. Eğitim verilerine ait Şekil 4a'da 5\*1, Şekil 4b'de 6\*1, Şekil 4c'de 5\*5\*1 ve Şekil 4d'de 5\*6\*1 ağ yapılarında tahmini yapılan değerler grafiksel olarak gösterilmiştir

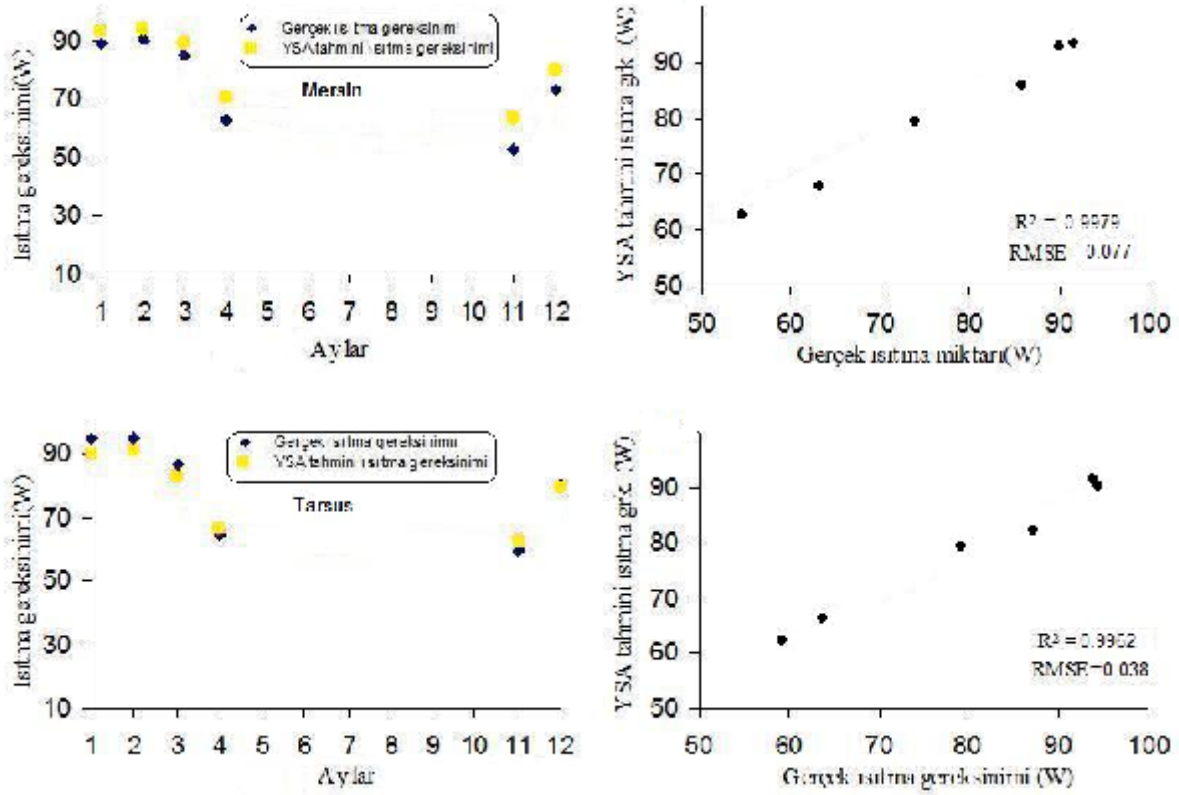
Çizelge 2. Eğitim verileri için farklı ağ yapıları kullanılarak seraların ısıtma gereksinimlerinin tahmininde elde edilen sonuçlar ve istatistiksel değerlendirme.

Ağ Yapısı	$\alpha_1$	$\alpha_0$	R <sup>2</sup>	RMSE	MAE	İterasyon Sayısı
5*1	0.9995	0.0309	0.999	0.0014	0.0008	100
6*1	0.9997	0.0111	0.998	0.0021	0.0009	100
5*5*1	0.9996	0.0230	0.999	0.0012	0.0004	100
5*6*1	0.9995	0.0309	0.999	0.0014	0.0008	100

#### 4. SONUÇLAR (CONCLUSION)

Bu çalışmada, yapay zeka uygulamalarının bir alt kolu olan yapay sinir ağları kullanılarak Mersin ili merkez ve ilçelerine ait seralar için birim alanda gerekli ısıtma gereksinimleri analiz edilmiştir. Yapılan çalışmada LM eğitim algoritmasına göre farklı ağ yapılarında Mersin iline ait seralarda gereksinim duyulan ısıtma ihtiyacı olan aylar, enlem, boylam, yükseklik ve ortalama sıcaklık verileri kullanılarak seraların ısıtma ihtiyacı tahmini yapılmıştır. Test ve eğitim verileri için en iyi sonucun alındığı ağ yapılarındaki R<sup>2</sup>, RMSE, ve MAE gibi istatistiksel analizleri yapılmıştır. Yapay sinir ağlarının uygun eğitim setinin kullanılmasıyla problemlerin çözümünde en uygun metod olarak ortaya konulduğu görülmektedir.

Bu çalışmada Mersin il ve ilçelerine ait toplam 48 veri kullanılmıştır. Toplam verinin 36' ı eğitim verisi, 12' si test verisi olarak kullanılmıştır. İlk aşamada Mersin ili ve Tarsus ilçesine ait veriler test ettirilmiştir. Bu değerler Levenberg-Marquardt (LM) eğitim algoritması kullanılarak değerlendirilmiştir. Test verileri farklı ağ yapılarında test ettirilerek tahmin sonucunun en iyi olduğu ağ yapısı tercih edilmiştir. Kullanılan farklı ağ yapılarında Mersin iline ait ilçelerinin (Anamur, Bozyazı, Aydınçık, Silifke, Erdemli ve Mezitli) ısıtma gereksinimi tahmini yapılmıştır. Yapay sinir ağlarında test verisi olarak kullanılan Mersin ilinin ve Tarsus ilçesinin LM eğitim algoritmasında farklı ağ yapılarında deneme yoluyla tahmin edilen ısıtma ihtiyacı en iyi tahmin sonuçları, 6\*1 ağ yapısında 0.9979 tahmin (R<sup>2</sup>) değeri, 0.077 RMSE ve 0.070 MAE değeri elde edilmiştir. Test verilerinin tahmininde farklı iterasyon sayıları kullanılmıştır ve en iyi sonuç 300 iterasyon (adım) sayısında alınmıştır.



Şekil 3. Test verilerine ait seraların gerçek değerleri ile yapay sinir ağlarında tahmin edilen ısıtma gereksinimlerinin karşılaştırılması.

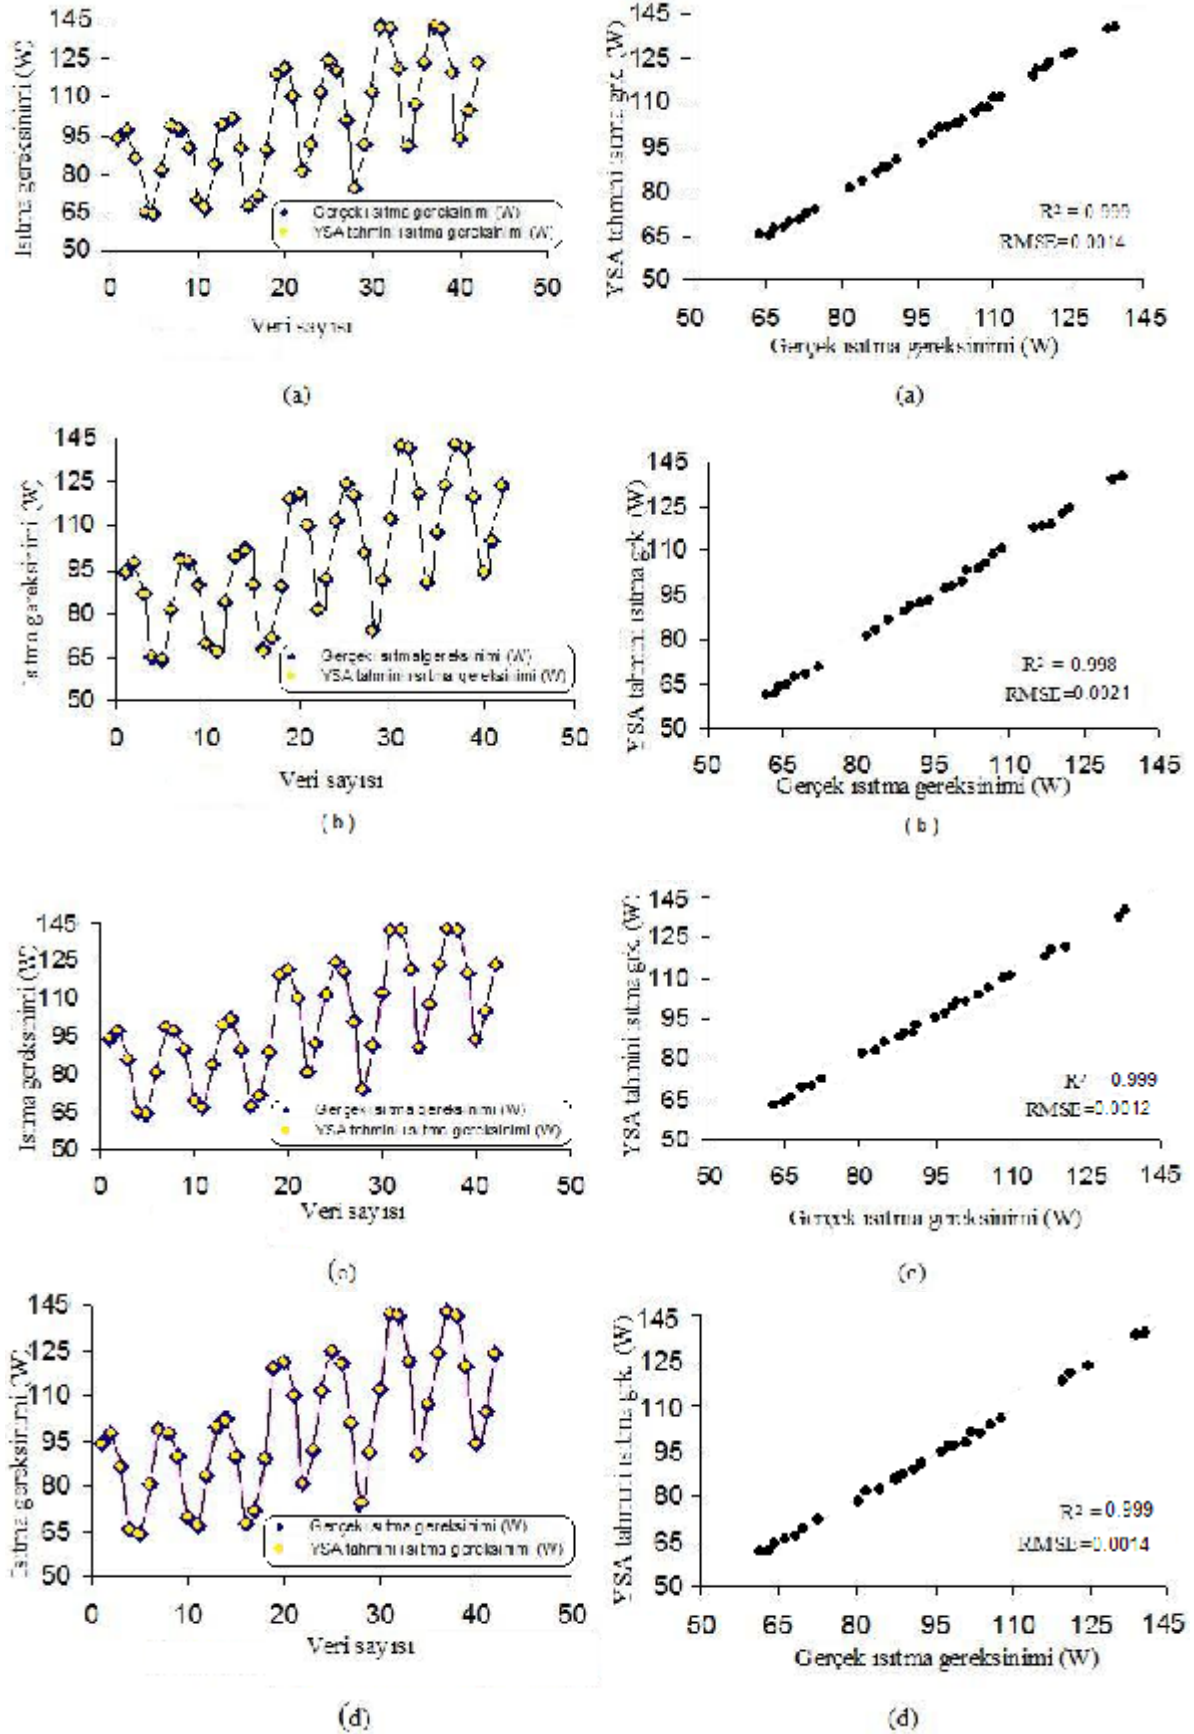
Yapay sinir ağları modelinde Mersin ilçeleri (Anamur, Bozyazı, Aydıncık, Silifke, Erdemli ve Mezitli) eğitim verisi olarak kullanılmıştır. Eğitim verileri LM eğitim algoritmasında farklı ağ yapıları kullanılarak tahmini yapılmıştır. Eğitim verileri için 100 iterasyon sayısında 5\*1, 5\*5\*1 ve 5\*6\*1 ağ yapılarında tahmin değeri ( $R^2$ ) 0.999 olarak elde edilmiştir. 6\*1 ağ yapısında  $R^2$  değeri 0.998 olarak elde edilmiştir. 5\*1, 6\*1, 5\*5\*1 ve 5\*6\*1 ağ yapılarında RMSE ve MAE değerleri sırasıyla 0.0014, 0.0021, 0.0012, 0.0014 ve 0.0008, 0.0009, 0.0004, 0.0008 olarak elde edilmiştir.

Yapay sinir ağları, bilgisayar ortamında, karar veren, sonuç çıkararak, yetersiz veri durumlarında eldeki verilerden sonuç çıkarabilen, daha az veri kullanılmasıyla en iyi sonuca ulaşma yeteneği olan, öğrenen, hatırlayan bir algoritmadır. Yapay sinir ağlarının sağladığı bu avantajları nedeniyle özellikle mühendislik alanlarında olmak üzere birçok alanda kullanılmaktadır.

##### 5. KAYNAKLAR (REFERENCES)

1. Mahmoud, O.,A "Computer-based monitoring system to maintain optimum air temperature and relative humidity in greenhouses", Int. J. Agric. Biol., 6:1084–1088, 2004.
2. Boodley, J., The Commercial Greenhouse, 2nd edition, pp:123–135. Thomson Delmar Learning, 1996.
3. Nelson, P.V., Greenhouse Operation and Management, 6th edition, pp:128–147, Prentice Hall., 2002.

4. Trejo-Perea, M., Herrera-Ruiz, G., Rios-Moreno, J., Miranda, R. C. and Rivas-Arazia, E., "Greenhouse Energy Consumption Prediction using Neural Networks Models." Int. J. Agric. Biol., Mexico, Vol. 11, No. 1, 2009.
5. Alfons, G.J.M., O. Lansink, J. Versteegen and J. Van Den Hengel, "Investment decision making in Dutch greenhouse horticulture", Netherlands. J. Agric. Sci., 49: 357–368, 2001.
6. Korner, G. and V. Straten, "Decision support for dynamic greenhouse climate control strategies", Computers Electronics Agric., 60: 18–30, 2008.
7. Keskin, M. E., Taylan, E. D., "Orta Karadeniz Havzasındaki Akımların Stokastik Modellemesi", İMO Teknik Dergi, 4271-4291, 2007.
8. Seginer, I., "Some Artificial Neural Network Applications to Greenhouse Environmental Control", Computers and Electronics in Agriculture, 18, 167-186, 1997.
9. Ehret, D.L., Hill, B.D., Raworth, D.A., Estergaard, B., "Artificial Neural Network Modelling to Predict Cuticle Cracking in Greenhouse Peppers and Tomatoes", Computers and Electronics in Agriculture 61, 108–116, 2008.
10. Frausto, H.U., Pieters, J.G., "Modelling Greenhouse Temperature Using System Identification by Means of Neural Networks", Neurocomputing 56, 423 – 428, 2004.



Şekil 4. Eğitim verilerine ait seraların gerçek değerleri ile yapay sinir ağlarında tahmin edilen ısıtma gereksinimlerinin değerlerinin karşılaştırılması.

11. Linker, R., Seginer, I., "Greenhouse Temperature modeling: A Comparison Between Sigmoid Neural Networks and Hybrid Models", *Mathematics and Computers in Simulation* 65, 19–29, 2004.
12. Ferreira, P.M., Fariab, E.A., Ruano, A.E., "Neural Network Models in Greenhouse Air temperature Prediction", *Neurocomputing* 43, 51–75, 2002.
13. Zabeltitz, C.V.. Solar Energy. "Energy Conservation and Renewable Energies for Greenhouse Heating" (Edited by: C.V: Zabeltitz), *FAO-Reur Technical Series*, 3:122-128, 1988.
14. Anonymous, Heating, Ventilating and Cooling Greenhouses, Revision approved February 2003, reaffirmed February 2008 as an American National Standard, 2008.
15. Landeras, G., Ortiz-Barredo, A., Lopez, J.J., "Comparison of Artificial Neural Network Models and Empirical and Semi-Empirical Equations For Daily Reference Evapotranspiration Estimation in the Basque Country (Northern Spain)", *Agricultural Water Management*, 95:553-565, 2008.
16. Traore S., Wang, Y.M., Kerh T., "Artificial Neural Network for Modeling Reference Evapotranspiration Complex Process in Sudano-Sahelian Zone", *Agricultural Water Management*, AGWAT-2943; 8., 2010.
17. Neter, J., M.H. Kutner, J. Nachtsheim and W. Wasserman, *Applied Linear Statistical Models*, 4th edition, pp: 266–279, Irwin, 1996.
18. Linker, R., Seginer, I., Gutman, P.O., "Optimal CO<sub>2</sub> Control in a Greenhouse Modeled With Neural Networks", *Computers and Electronics in Agriculture* 19, 289–310, 1998.