

BİNALARIN YERDEN ISITMA SİSTEMLERİNDE ISI TAŞINIMININ YAPAY SİNİR AĞLARI KULLANILARAK İNCELENMESİ

Refet KARADAĞ*

*Doç.Dr., Harran Üniversitesi,
Makina Mühendisliği Bölümü, Şanlıurfa,
refetkaradag@yahoo.com*

Mahmut BİLGEHAN

*Yrd. Doç. Dr., Zirve Üniversitesi,
İnşaat Mühendisliği Bölümü, Gaziantep,
mahmut.bilgehan@zirve.edu.tr*

ÖZET

Bu çalışmada, binaların yerden ısıtma sistemlerinde Nusselt ve Rayleigh sayılarının belirlenmesi için yapay sinir ağlarının kullanılabilmesi ortaya konmaktadır. Literatürde konuyla ilgili verilen sayısal değerlerin bir kısmı eğitim amaçlı, bir kısmı ise kullanılan yapay sinir ağı modelinin performansını değerlendirmede kullanılmıştır. Elde edilen sonuçlar sayısal verilerle karşılaştırılmış ve grafiksel olarak verilmiştir. Yapay sinir ağları ve sayısal yöntemle elde edilen sonuçların uyum içerisinde olduğu görülmüştür.

Anahtar Kelimeler: Kapalı ortamda ısı transferi, doğal taşınım, yerden ısıtma, yapay sinir ağları, Nusselt sayısı.

The Investigating of Heat Convection in Floor Heating Systems of Buildings by Using Artificial Neural Networks

ABSTRACT

In this study, it is shown that artificial neural networks (ANN's) can be used for determining the Nusselt and Rayleigh numbers in floor heating systems of buildings. Some data provided in literature is used for training of the artificial neural network and the other data is used for testing the ANN model. The results are compared with numerical results. It is observed that the results found by artificial neural network model and numerical method are in good agreement with each other.

Keywords : Heat transfer in enclosures, free convection, floor heating, artificial neural networks, Nusselt number.

* İletişim Yazarı

Geliş tarihi : 03.01.2011
Kabul tarihi : 21.04.2011

GİRİŞ

Yapay sinir ağları (YSA), ısı transferi analizlerinin değişik uygulamalarında kullanılmaktadır. YSA ortam içindeki sıcaklık dağılımı, ısı taşınım katsayısı, ortalama ısı transfer katsayısı ve farklı ortam şartlarında ısı transferinin incelenmesi gibi amaçlarla kullanılmaktadır. Literatürde konuyla ilgili olarak yapılmış bazı çalışmalar aşağıda özetlenmektedir.

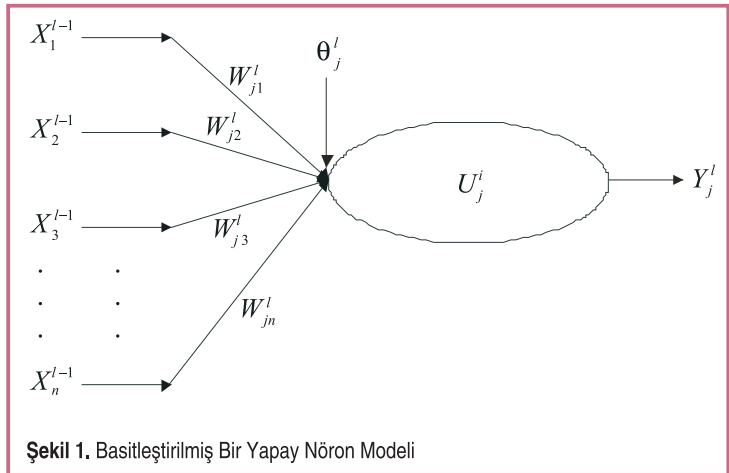
Xie ve arkadaşları [1], gövde borulu ısı değiştiricilerinde ısı transferi için elde ettikleri deneysel verileri; YSA modelinde eğitim ve test amaçlı kullanarak, test sonuçlarının deneysel verilerle % 2'den daha düşük bir hata ile uyum sağladığını göstermişlerdir. Jambunathan ve arkadaşları [2] sinir ağlarını kullanarak deneysel verilerden ısı transfer katsayıları elde etmişlerdir. Yigit ve Ertunç [3] değişik deney şartlarında bir ısı değiştiricisinin performansını test ederek, deneysel verileri YSA modelini eğitmede kullanmışlardır. Ertunç ve Hosoz [4], buharlaştırıcı kondenserli bir soğutma sisteminin performansı konusunda bulunduğu deneysel verileri YSA modelinde eğitim ve test amaçlı kullanmışlardır. Khalifa [5], bina uygulamaları için yalıtımlı düşey ve yatay yüzeylerde ısı taşınım katsayılarıyla ilgili yapılmış çalışmaların bir özetini sunmuştur. Ritter ve Kilkis [6], Li ve arkadaşları [7], Min ve arkadaşları [8], Awbi [9], Alamdari ve Hammond [10], CIBSE [11] ve Awbi ile Hatton [12] yerden ısıtma sistemlerinde değişik ısı şartlarında ısı taşınımı için korelasyonlar geliştirmişlerdir. Bu çalışmada, YSA modelinin sayısal çözümlere ve korelasyonlara alternatif çözüm sunduğu ortaya konmaktadır.

Yapay sinir ağları; esasen birçok biyolojik ayrıntı ihmal edilmekle birlikte, biyolojik sinir sisteminin işleyişine dayanmaktadır. Yapay sinir ağları, değişken ağırlıklara sahip bağlarla birbirine bağlanmış birçok işlem elemanlarından oluşan çok büyük ölçekte paralellik arz eden sistemlerdir. Birçok sinir ağı modellerinde, geri yayımlı ağlar diğerlerine göre daha yaygın olarak kullanılmaktadır [13, 14]. Yapay sinir ağları, terim olarak istatistik ve yapay zekanın bir bileşimi olan sinir ağı modellerini ifade etmektedir. Beyindeki merkezi sinir sistemine benzetilerek tasarlanmış olan YSA modelleri teorik olarak nöroloji biliminin konusudur [15, 16]. Genel olarak sinir ağı, eğitim ve test (simülasyon) olmak üzere iki farklı devreden oluşmaktadır [16]. Eğitim işlemi, bilinen girdi-çıkı veri kümelerinin sinir ağına işleme konulmasından ibarettir. Veriler, çok katmanlı perseptrona (multi linear perceptron-MLP) sahip ileri beslemeli sinir ağının içerisinden geçerek işlem görmektedir. Sinir ağı, belirlenmiş bir doğruluk seviyesine göre hedef çıktıları elde etmek amacıyla her bir nöronun ağırlıklarını ayarlayarak başarılı iterasyonlar gerçekleştirmektedir. Nöron ağırlıklarını ayarlama işlemi, hesaplanan ve hedef çıktı modeli arasındaki ortalama karesel hata olarak adlandırılan ağ hatasını

minimize edecek şekilde yapılmaktadır. Güvenilir bir şekilde eğitilmiş ve test edilmiş olan YSA modeli, artık hiç görmediği giriş verileri girildiğinde daha önceden ayarlanmış olan ağırlıkları kullanarak, çıktı değerlerini tahmin edebilecek genel bir yapıya sahip olmaktadır [17-20].

Bir ağı eğitilmesi için birkaç yöntem kullanılmaktadır. Bunlardan, çoklu pörseptronlar (multi linear perceptron) için en yaygın olarak kullanılan yöntem geri yayılma algoritmasıdır (back propagation algorithm). Bu algoritmada girdi verileri, girdi tabakasından ve gizli tabakadan geçerek çıktı tabakasına doğru yayılmaktadır. Daha sonra, ağı hesaplanan hatası, çıktı tabakasından girdi tabakasına doğru yayılmaktadır. Bu işlemin amacı, ortalama karesel hatanın minimize edilmesi suretiyle ağırlıkların ayarlanmasıdır. Bu işlem, hata tercih edilen bir seviyeye ulaşmaya kadar tekrar edilmektedir [17, 21].

Şekil 1'de basitleştirilmiş bir yapay nöron modeli gösterilmiş ve böyle bir nöronda gerçekleşen işlemler (1-3) denklemleriyle verilmiştir [22].



Şekil 1. Basitleştirilmiş Bir Yapay Nöron Modeli

$$U_j^l = \sum_{i=1}^n W_{ji}^l X_i^{l-1} + \theta_j^l \quad (1)$$

$$Y_j^l = \phi(U_j^l) \quad (2)$$

$$\phi_j^l = \frac{1}{1 + e^{-(U_j^l - \theta_j^l)}} \quad (3)$$

Burada, U_j^l l tabakasındaki j nöronunun ağ girdisini, X_i^{l-1} $l-1$ tabakasındaki i nöronundan gelen girdi değerini, θ_j^l eşik değerini, W_{ji}^l l tabakasındaki j nöronu ile önceki tabakada bulunan i nöronu arasındaki ağırlık değerini ifade etmektedir. Y_j^l l tabakasındaki j nöronunun çıktısını, ϕ nonlineer aktivasyon fonksiyonunu temsil etmektedir. Ayrıca, ϕ_j^l l tabakasındaki j nöronu için aktivasyon fonksiyonunu göstermektedir.

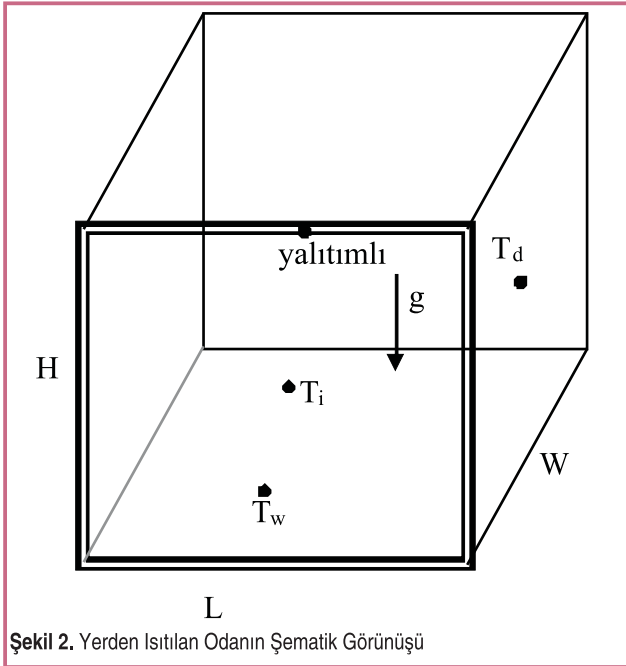
Geriy yayımlı sinir ağlarında, genelleştirilmiş delta kuralı (generalized delta rule), öğrenme mekanizması olarak yaygın bir şekilde kullanılmaktadır [23]. Böyle bir algoritmanın kullanımı, ağ ağırlıklarını hızlı bir şekilde güncellemektedir [22].

Yapay sinir ağları ile modelleme; son yıllarda gittikçe yaygınlaşmakta ve mühendislik problemlerinin çözümünde de başarılı bir şekilde kullanılmaktadır [22, 24, 25, 26, 27]. Bu çalışmada binaların yerden ısıtma sistemlerinde ısı taşınımının belirlenmesi için üç tabakalı bir yapay sinir ağı mimarisi kullanılmıştır.

ÇALIŞMA ŞARTLARI VE YÖNTEM

Yerden ısıtmada yalıtımlı tavan şartlarında bulunan sayısal veriler [28]; YSA modelinde eğitim ve test amaçlı kullanılmışlardır. Sayısal veriler, sonlu fark yöntemine dayanan FLUENT programı kullanılarak elde edilmiştir [29]. Problemin geometrisi ve mesh işlemi için GAMBIT 1.3 kullanılmıştır. Yerden ısıtılan odanın şematik görünüşü Şekil 2'de görülmektedir.

Nusselt sayısı ve Rayleigh sayılarıyla ilgili sayısal veriler yalıtımlı tavan şartlarında, sabit taban ve duvar sıcaklıkları sınır şartlarında elde edilmişlerdir. Çözümler değişik taban



Şekil 2. Yerden ısıtılan odanın şematik görünüşü

sıcaklıklarında (27-57 °C) ve duvar sıcaklıklarında (10, 15, 20 ve 25 °C) elde edilerek, duvar ve taban sıcaklıklarıyla oda boyutlarının ısı transferine etkisi araştırılmıştır.

Çalışma türbülanslı bölgede olup K-Epsilon standart türbülans modeli kullanılmıştır. Bu model enerji ve momentum denklemlerinde türbülans kaynaklı terimleri (eddy viskozitesi ve eddy iletkenliği) hesaplamak için türbülans kinetik enerjisi (k) ve onun yayılma hızını (ε) kullanılmaktadır. Literatürde yapılan çalışmalar [30], bu modelin doğal konveksiyon problemlerinin çözümü için uygun olduğunu göstermektedir.

Yüzeyler sabit sıcaklık sınır şartına göre tanımlanarak ortalama oda sıcaklığı ve yüzeylerdeki ısı taşınım değerleri hesaplandıktan sonra ısı taşınım katsayıları ve Nusselt değerleri bulunmuştur. Sayısal bulgular literatürdeki deneysel çalışmalarla [7,8] karşılaştırılarak, benzer çalışma şartlarında % 10 civarlarında sapmayla uyum içinde olduğu görülmüştür.

Eğitim ve test amaçlı kullanılan odanın boyutları ve yüzey sıcaklıkları Tablo 1'de verilmiştir. Boyutlar ve iç yüzey sıcaklıkları programa girdi olarak verilmiş, tabandaki Nusselt sayısı ve oda sıcaklığı değerleri hesaplanmıştır. Boyutsuz Rayleigh sayısı, havanın ısı özelliklerine ve odanın geometrik boyutlarına bağlı olarak Denklem 4'ten hesaplanmaktadır.

$$Ra = \frac{g\beta(T_w - T_i)}{\nu^2} prL^3 \quad (4)$$

Burada; g yer çekimi ivmesini, β ısı genleşme katsayısını (β = 1/T), T_w taban sıcaklığını, T_i oda sıcaklığını, ν havanın kinematik viskozitesini, P_r havanın prandtl sayısını, L ise taban karakteristik uzunluğunu ifade etmektedir.

Farklı ısı şartlarında sayısal olarak bulunan Nusselt ve Rayleigh sayıları arasındaki ilişki grafiksel olarak incelenmiştir. Nusselt sayısı, ısı taşınım katsayısının belirlenmesinde kullanılan ve Denklem 5 ile ifade edilen boyutsuz bir sayıdır.

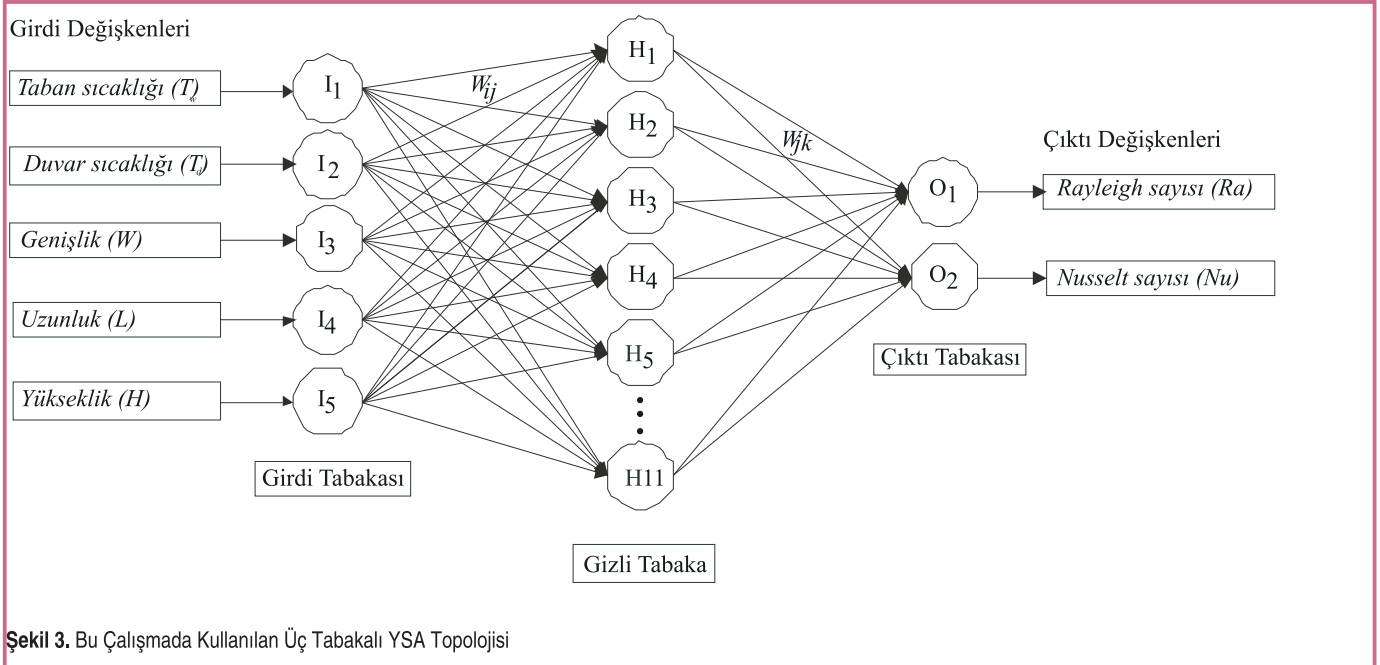
$$Nu = \frac{hL}{K} \quad (5)$$

Burada; h ısı taşınım katsayısını, K ise ısı iletim katsayısını göstermektedir.

Nusselt ve Rayleigh sayıları için bulunan sayısal bulguların bir

Tablo 1. YSA Modelini Eğitim ve Test Etmede Kullanılan Oda Boyut ve Yüzey Sıcaklıklarının Sayısal Aralıkları (tavan yalıtımlı)

	Boyutlar (m)			Sıcaklıklar (°C)	
	L	H	W	Taban (T_w)	Duvar (T_d)
Eğitim amaçlı kullanılan boyutlar ve sıcaklıklar	1, 2, 4, 6	1, 1.75, 2.5, 3.25	1, 2, 4, 6	27-67	10, 20
Test amaçlı kullanılan boyutlar ve sıcaklıklar	1, 2, 4, 6	1, 1.75, 2.5, 3.25	1, 2, 4, 6	27-67	15, 25



Şekil 3. Bu Çalışmada Kullanılan Üç Tabakalı YSA Topolojisi

kısmı YSA modelinde eğitim amaçlı, diğer bir kısmı ise test amaçlı kullanılarak, sonuçlar sayısal verilerle karşılaştırılmaktadır.

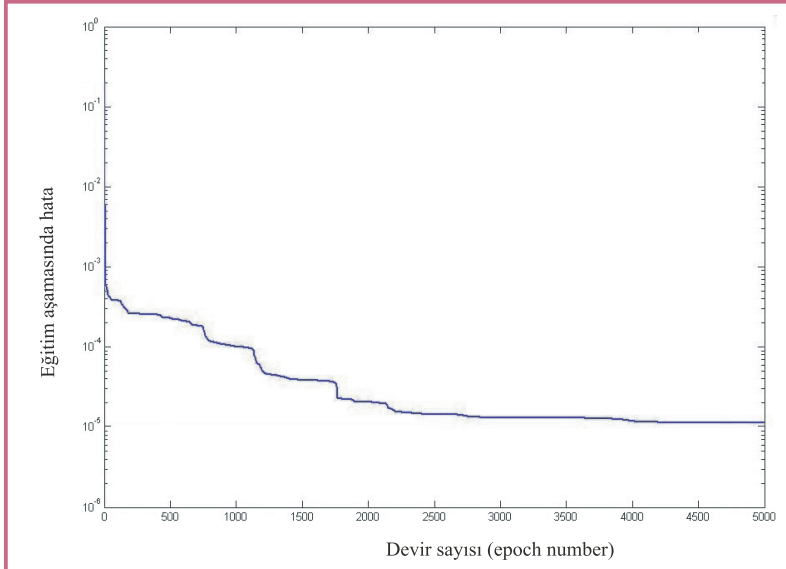
Bu çalışmada, Şekil 3'te görülen nöron tabakaları arasında W_{ij} ve W_{jk} ağırlıklarına sahip bağlarla birbirine bağlı olan 5 nöronlu bir girdi tabakası, 11 nöronlu bir gizli tabaka ve 2 nöronlu bir çıktı tabakasından oluşan tipik birçok katmanlı ileri beslemeli (feed forward) YSA modeli kullanılmıştır. Eğitim aşamasında rastgele alınan ilk ağırlık değerleri, hesaplanan ve bilinen çıktı değerleri karşılaştırılıp sonuca ulaşmaya kadar değiştirilerek ilerlemektedir. Hataları minimize ederek gerekli olan ağırlık ayarlamalarını yapabilmek amacıyla her hata geriye doğru yayılmaktadır. Bu durum Şekil 3'te sağdan sola şeklinde ifade edilmektedir.

Girdi tabakası; odanın uzunluğu, yüksekliği, genişliği, duvar sıcaklığı ve taban sıcaklığı değişkenlerini temsil eden 5 nöron; çıktı tabakası ise, girdi tabakasındaki beş değişken tarafından nonlinear bir şekilde etkilenen Nusselt sayısı ve oda sıcaklığına bağlı olarak bulunan, Rayleigh sayısını temsil eden 2 nöronlu oluşmaktadır. Aradaki gizli tabakada ise 11 nöron kullanılmıştır. Elde mevcut olan bütün veri grubu, ağırlık öğrenmesi için kullanılan eğitim kümesi (training set) ve eğitilmiş olan ağırlık performansını test edebilmek için kullanılan test kümesi (testing set) olmak üzere iki kümeye ayrılmıştır. Eğitim kümesi 73 ve test kümesi 69 adet girdi-çıkı verisinden oluşmaktadır. Eğitim ve test kümeleri için dikkate alınan girdi-çıkı verileri ile veri sayıları rastgele seçilmiştir.

Burada, ağırlıkları ayarlamak için geri yayımlı momentum yöntemi kullanılmıştır. Bu yöntem, Rumelhart ve arkadaşları [31] tarafından önerilen geliştirilmiş delta kuralına dayanmaktadır. Yapay sinir ağı simülasyonunda, yakınsama

hızını arttırmak için öğrenme oranı (learning rate) kullanılmıştır. Nöronlarda aktivasyon fonksiyonu olarak sigmoid fonksiyonu kullanılmıştır. Çünkü, sigmoid fonksiyonunda girdi örüntüsüne devam eden, süreklilik gösteren ve ayrık olmayan cevaplar verilmektedir. Türevinin alınabilecek bir fonksiyon olmasından ve hassas değerlendirmelerin kullanılacağı problemler için uygulanması en uygun olan fonksiyonu temsil ettiğinden dolayı sigmoid fonksiyonu yaygın bir kullanıma sahiptir. Gizli tabakada kaç nöron kullanılacağına dair herhangi bir teori henüz mevcut olmadığından dolayı, değişik ağ yapıları denenmek suretiyle gizli tabakadaki uygun nöron sayısı elde edilmiştir. Sinir ağı eğitim aşaması, hatanın yeterince küçük seçilmesi ile 5000 devir (epoch) sonunda durdurulmuştur. Yapay sinir ağı modelinin eğitim aşaması için ortaya çıkan hata grafiği Şekil 4'te gösterilmiştir. Şekilden, ağ eğitiminin hassas ve güvenilir olan ortalama karesel hata esasına göre yapıldığı görülmektedir.

Yapay sinir ağı simülasyonunu yapabilmek amacıyla MATLAB programlama dilinde, yapay sinir ağı çalışma ortamını (neural network toolbox) içeren bir bilgisayar program kodu kullanılmıştır. En uygun YSA model yapısını bulabilmek için bu program kullanılarak, farklı YSA mimarileri denenmiştir. Gizli tabakadaki nöron sayısının tespiti için birçok denemeler yapılmış ve bu denemeler sonunda uygun nöron sayısı elde edilmiştir. Yapay sinir ağı mimarisinin eğitiminde kullanılacak olan gizli tabakadaki uygun nöron sayısını elde etmek için, aktivasyon fonksiyonu ve gizli tabakadaki nöron sayısının değişik kombinasyonları kullanılmıştır. Eğitim sonrasında YSA modeli test edilmiş, sonuçlar ortalama karesel hatanın karekökü (root mean squared error, RMSE) ve istatistiksel determinasyon katsayısı (coefficient of determination, R^2) dikkate alınarak mukayese



Şekil 4. Yapay Sinir Ağı Eğitim Aşaması İçin Hata Grafiği

edilmiştir. Test veri kümesi, eğitilmiş olan ağın performansının güvenilirliğini değerlendirmek için kullanılmaktadır. Eğitim veri kümesi, analizden önce normalize edilmekte ve ileri beslemeli geri yayımlı sinir ağının tahmin edebilme yeteneği sınırlanmaktadır. Tahmin performansı RMSE değeri dikkate alınarak kıyaslanmaktadır. Daha düşük RMSE değerinin daha yüksek tahmin performansını göstereceği açıktır.

Uygulanmış olan birçok sinir ağı simülasyonu sonucunda bulunan en uygun ağ parametreleri şu şekilde elde edilmiştir: Geri yayılma öğrenme kuralı olarak eğimli iniş algoritması (gradient descent algorithm), gizli tabaka sayısı 1, gizli tabakada kullanılan nöron sayısı 11, öğrenme oranı 0.4, momentum katsayısı 0.9, eğitim performansı için hedeflenen hata değeri 10^{-7} , eğitim aşamasındaki maksimum devir sayısı 5000. Yapay sinir ağı mimarisi, 5-11-2 (girdi-gizli-çıkış tabakaları nöron sayısı) şeklinde modellenmiştir. Bu çalışmada kullanılan bazı ağ parametreleri ve aldığı değerler Tablo 2'de verilmiştir.

Tablo 2. Kullanılan Yapay Sinir Ağı Modeline Ait Parametreler ve Bazı Özellikler

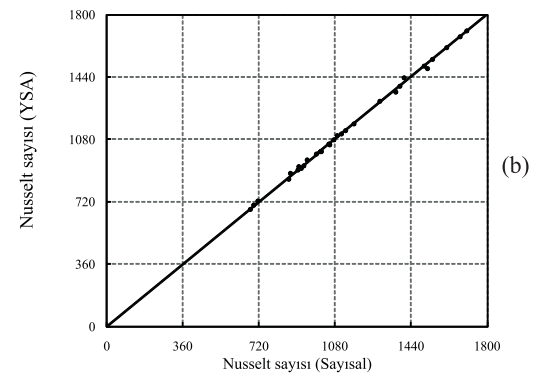

Girdi tabakasındaki parametreler	T_w, T_d, W, L, H
Girdi tabakasındaki nöron sayısı	5
Gizli tabakadaki nöron sayısı	11
Çıkış tabakasındaki parametreler	Ra, Nu
Çıkış tabakasındaki nöron sayısı	2
Öğrenme oranı	0.4
Momentum katsayısı	0.9
Hedef hata değeri	10^{-7}
Maksimum devir (epoch) sayısı	5000

Algoritmanın performansı, öğrenme oranı değerine oldukça duyarlıdır. Eğer öğrenme oranı çok büyük bir değer olarak ayarlanmış ise algoritma salınım yapmakta ve sistem kararsız hâle gelebilmektedir. Eğer çok küçük bir değer olarak ayarlanmış ise algoritmanın yakınsaması çok uzun sürebilmektedir [19].

BULGULAR VE DEĞERLENDİRME

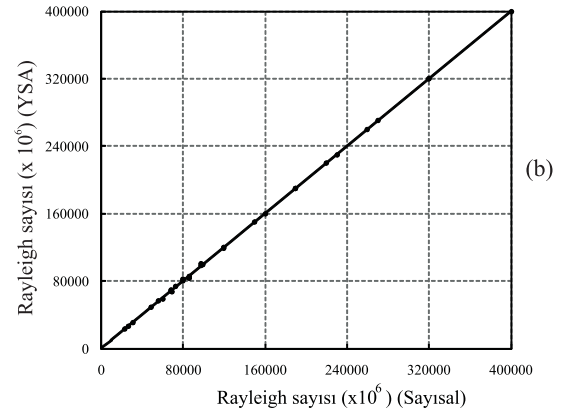
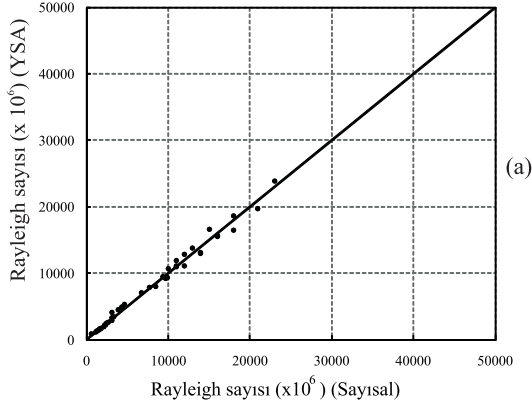
Farklı boyutlarda ($L = W = 1-6, H = 1-3.25$), iki farklı duvar sıcaklığında ($T_d = 10 \text{ }^\circ\text{C}$ ve $20 \text{ }^\circ\text{C}$) ve farklı taban sıcaklığında ($T_w = 27-67 \text{ }^\circ\text{C}$), sayısal yöntem ve YSA modeliyle eğitim aşaması için elde edilen Nusselt ve Rayleigh sayıları Şekil 5 ve 6'da karşılaştırılmıştır. Şekiller, sonuçların uyum içerisinde olduğunu göstermektedir.

Farklı boyutlarda ($L = W = 1-6, H = 1-3.25$), farklı duvar sıcaklığında ($T_d = 15 \text{ }^\circ\text{C}$ ve $25 \text{ }^\circ\text{C}$) ve farklı

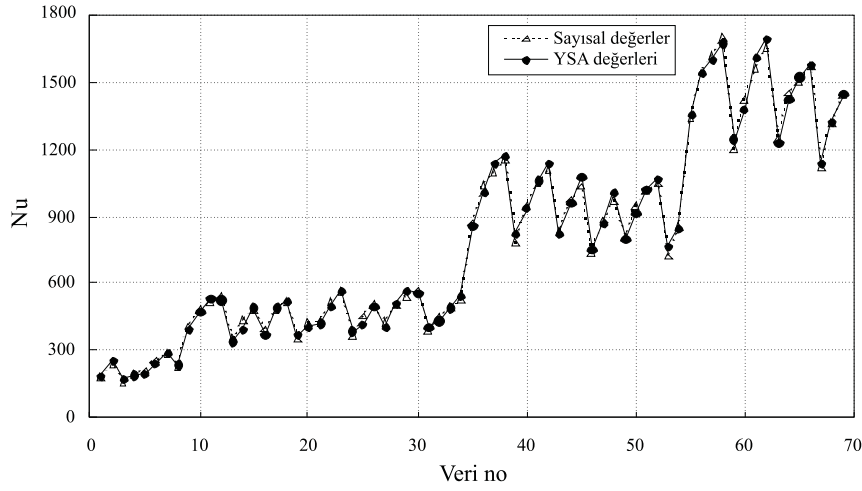


Şekil 5. Eğitim Aşamasında YSA Modeli ve Sayısal Yöntemle Bulunan Nusselt Sayısı Değerlerinin Karşılaştırılması (a) $L = W = 1-2$, (b) $L = W = 4-6$

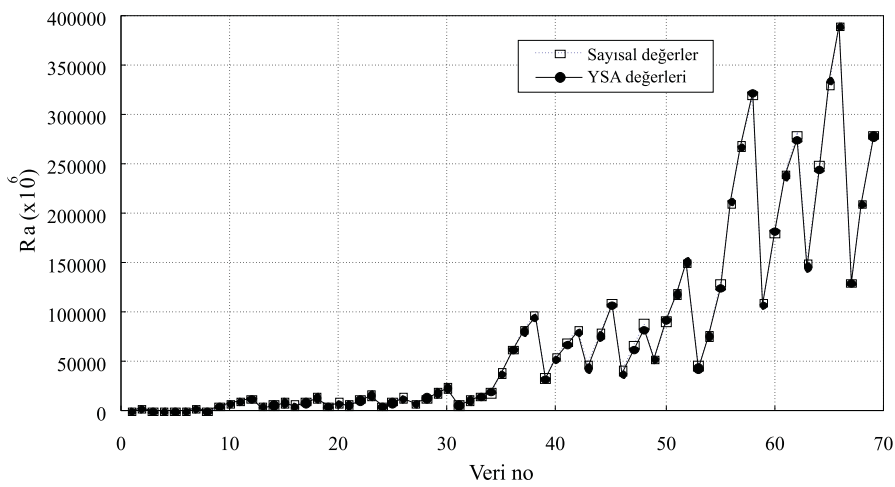
taban sıcaklığında ($T_w = 27-67 \text{ }^\circ\text{C}$), sayısal yöntem ve YSA modeliyle bulunan Nusselt ve Rayleigh sayısı değerleri, sırasıyla, Şekil 7 ve 8'de grafiksel olarak karşılaştırılmıştır. Şekil



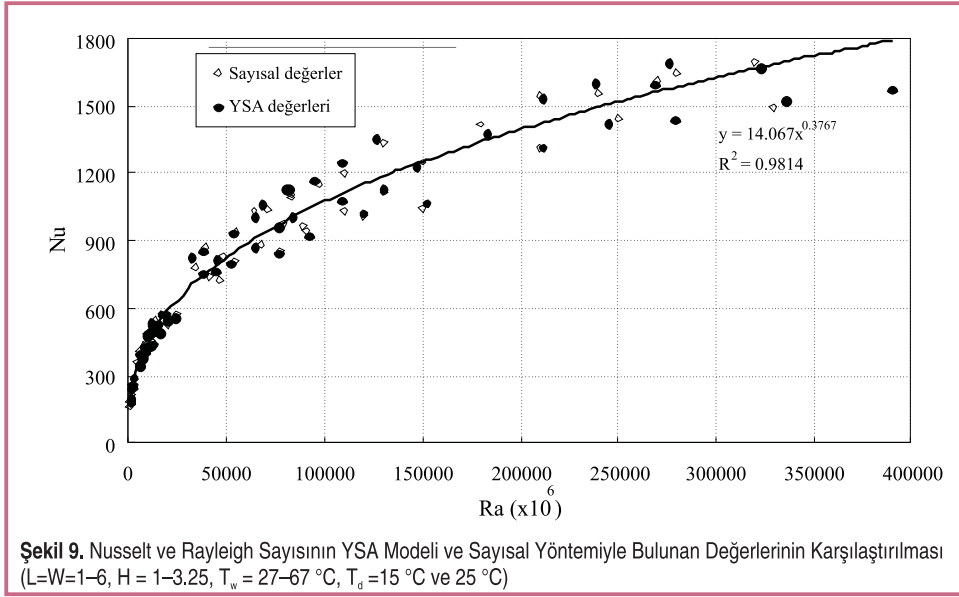
Şekil 6. Eğitim Aşamasında YSA Modeli ve Sayısal Yöntemiyle Bulunan Rayleigh Sayısı Değerlerinin Karşılaştırılması (a) $L = W = 1-2$, (b) $L = W =$



Şekil 7. YSA Modeli ve Sayısal Yöntemiyle Bulunan Nusselt Sayısı Değerlerinin Karşılaştırılması ($L = W = 1-6$, $H = 1-3.25$, $T_w = 27-67^\circ\text{C}$, $T_d = 15^\circ\text{C}$ ve 25°C)



Şekil 8. YSA Modeli ve Sayısal Yöntemiyle Bulunan Rayleigh Sayısı Değerlerinin Karşılaştırılması ($L = W = 1-6$, $H = 1-3.25$, $T_w = 27-67^\circ\text{C}$, $T_d = 15^\circ\text{C}$ ve 25°C)



9'da ise, seçilen YSA mimarisinin test aşamasında her iki yöntemle bulunan değerler, her iki çıktı için grafiksel olarak gösterilmiştir. Şekillerden, sonuçların çok küçük bir hata ile uyum içinde olduğu görülmektedir.

Şekil 7-9'da sınır ağları için verilmiş olan değerler, eğitim aşamasında kullanılmayan ve eğitilmiş olan ağın ilk defa gördüğü test verisidir. Şekiller açık bir şekilde, hesaplanmış veriler ile tahmin edilmiş verilerin birbirine çok yakın olduklarını göstermektedir (maksimum sapma Nu için % 8.14 ve Ra için % 16.13'tür). Geri beslemeli algoritmanın doğasından dolayı ortalama karesel hatalarda bazı dalgalanmaların gözlenmesi sürpriz değildir (Şekil 4). 11 adet gizli nörona sahip bir gizli tabakalı YSA mimarisine yapılan analizlerde en uygun öğrenme oranı 0.4 olarak elde edilmiştir.

Eğitim ve test aşamasında yapılan analizlerde elde edilen R² ve hata (RMSE) değerleri Tablo 3'te verilmiştir. Eğitim aşamasında daha büyük R² ve daha küçük RMSE değerinin bulunması doğaldır. Çünkü, oluşturulan YSA modeline test aşamasında, daha önce hiç karşılaşmadığı datalar verilmektedir. Bu nedenle bu aşamada hatalar artabilmektedir. Test aşamasında bulunan en iyi R² ve RMSE, sırasıyla, Nu analizinde elde edilen 0.9794 ve 9.944 değeridir. Buna karşılık, analizler sonucunda elde edilen en kötü R² ve RMSE değeri, sırasıyla, Ra analizinde elde edilen 0.9790 ve 9.986 değeridir. Elde edilen iyi ve en kötü değerlerin de birbirine yakın olduğu görülmektedir. R²'nin 1.0 değerinden uzaklaşmasıyla hata değeri de artmaktadır.

Tablo 3. Eğitim ve Test Devresinde Elde Edilen R² ve RMSE Değerleri

		R ²	RMSE
Eğitim devresi	Nu	0.9896	8.532
	Ra	0.9907	8.259
Test devresi	Nu	0.9794	9.944
	Ra	0.9790	9.986

SONUÇ

Bu çalışma, ısı transferi problemleri için iyi bir teknik olan çok katmanlı ileri beslemeli geri yayımlı YSA modelinin uygulama kabiliyetini göstermektedir. Bu çalışmada kullanılan YSA modeli, yerden ısıtmalı sistemde ısı taşınım katsayısının tahmini için yeterince iyi bir performans göstermiştir. Analizlerde, bir gizli katmanlı ileri beslemeli geri yayımlı ağ mimarisi ve eğimli iniş algoritması kullanımının uygun bir yöntem olduğu görülmüştür. Grafiklerden de görüleceği gibi, YSA modeliyle yapılan tahminlerle hesaplanmış değerlerin birbirine yakın olduğu gözlenmiştir. Maksimum sapma Nu için % 8.14 olurken, Ra için % 16.13 olarak elde edilmiştir.

Modern bir yöntem olarak yapay sınır ağlarının binaların ısı transferinin değişik uygulamalarında kullanılabilme olanağı mevcuttur. Daha ileri bir çalışma olarak yazarlar, ısı taşınımının ve ışınımının farklı uygulamalarında bu yöntemin uygulanabilirliğiyle ilgili çalışmalarına devam etmektedirler. Ayrıca, Nu ve Ra için elde edilen sapmalar, standart ısı transferi korelasyonlarından elde edilenlerle karşılaştırılarak, YSA'nın mevcut korelasyonların alternatifi olup olamayacağı konusu da ileride yapılacak olan çalışmalarda araştırılabilir.

SEMBOLLER

- Nu Nusselt sayısı
- Ra Rayleigh sayısı
- H yükseklik (m)
- L uzunluk (m)
- W genişlik (m)
- ΔT sıcaklık farkı (°C, K)
- h ısı taşınım kats.(W/m²K)
- T_d duvar sıcaklığı

T_w	taban sıcaklığı
T_i	oda sıcaklığı
g	yer çekim ivmesi (m/s^2)
p_r	prandtl sayısı
K	ısı iletim kats. (W/mK)
U_j^1	l tabakasındaki j nöronunun ağ girdisi
X_i^{l-1}	l-1 tabakasındaki i nöronundan gelen girdi değeri
θ_j^1	eşik değeri
W_{ji}^1	tabakasındaki j nöronu ile önceki tabakadaki i nöronu arasındaki ağırlık değeri
Y_{ji}^1	l tabakasındaki j nöronunun çıktısı
ϕ	lineer olmayan aktivasyon fonksiyonu
ϕ_j^1	l tabakasındaki j nöronu için aktivasyon fonksiyonu
β	ısı genleşme katsayısı ($1/K$)
ν	kinematik viskozite (m^2/s)

KAYNAKÇA

- Xie, G.N., Wang, Q.W., Zeng, M., Luo, L.Q. 2007. "Heat Transfer Analysis for Shell-and-Tube Heat Exchangers with Experimental Data by Artificial Neural Networks Approach," *Applied Thermal Engineering*, 27, p. 1096–1104.
- Jambunathan, K., Hartle, S.L., Ashforth-Frost, S., Fontama, V. 1996. "Evaluating Heat Transfer Coefficients Using Neural Networks," *International Journal of Heat and Mass Transfer*, 39, p. 2329–2332.
- Yigit, K.S., Ertunc, H.M. 2006. "Prediction of the Air Temperature and Humidity at the Outlet of a Cooling Coil Using Neural Networks," *International Communications in Heat and Mass Transfer*, 33, p. 898–907.
- Ertunc, H.M., Hosoz, M. 2006. "Artificial Neural Network Analysis of A Refrigeration System With an Evaporative Condenser," *Applied Thermal Engineering*, 26, p. 627–635.
- Khalifa, A.J.N. 2001. "Natural Convective Heat Transfer Coefficient A Review I. Isolated Vertical and Horizontal Surfaces," *Energy Conversion and Management*, 42, p. 491–504.
- Ritter, L.T., Kilkis, B. 1998. "An Analytical Model for the Design of In-Slab Electric Heating Panels," *ASHRAE Transactions*, 2, p. 1112–1115.
- Li, L.D., Beckman, W.A., Mitchell, J.W. 1983. "An Experimental Study of Natural Convection in An Office Room, Large Time Results," *Solar Energy Laboratory, University of Wisconsin, Madison*.
- Min, T.C., Schutrum, L.F., Parmelee, G.V., Vouris, J.D. 1956. "Natural Convection and Radiation in A Panel-Heated Room," *ASHRAE Transactions*, 62, p. 337–358.
- Awbi, H.B. 1998. "Calculation of Convective Heat Transfer Coefficients of Room Surfaces for Natural Convection," *Energy and Buildings*, 28, p. 219–227.
- Alamdari, F., Hammond, G.P. 1983. "Improved Data Correlations for Buoyancy-Driven Convection in Rooms," *Building Services Engineering, Research & Technology*, 4(3), p. 106–112.
- CIBSE, CIBSE Guide, Vols. A, B and C, CIBSE, London, 1986.
- Awbi, H.B., Hatton, A. 2000. "Mixed Convection from Heated Room Surfaces," *Energy and Buildings*, 32, p. 153–166.
- Lippman, R. 1987. *An Introduction to Computing with Neural Nets*. IEEE ASSP Mag., 4, p. 4–22.
- Kisi, Ö. 2008. "Constructing Neural Network Sediment Estimation Models Using A Data-Driven Algorithm," *Mathematics and Computers in Simulation*, 79, p. 94–103.
- Tapkin, S. 2004. "A Recommended Neural Trip Distribution Model," Ph.D. Thesis, Middle East Technical University, Ankara.
- Tapkin, S., Tuncan, M., Arioz, O., Tuncan, A., Ramyar, K. 2006. "Estimation of Concrete Compressive Strength by using Ultrasonic Pulse Velocities and Artificial Neural Networks, Conference for Computer Aided Engineering and System Modeling," 11th FIGES User's Conference, Conference Proceedings, ISBN:975-98408-2-0, Turkey.
- Kartam, N., Flood, I., Garrett, J.H. 1997. *Artificial Neural Networks for Civil Engineers: Fundamentals and Applications*, New York.
- Rafiq, M.Y., Bugmann, G., Easterbrook, D.J. 2001. "Neural Network Design for Engineering Application," *Comput. Struct.*, 79, 1541–1552.
- MathWorks Inc., MatLab the Language of Technical Computing, Natick, M.A., USA: MathWorks Inc., Version 6, 1999.
- Ashour, A.F., Alqedra, M.A. 2005. "Concrete Breakout Strength of Single Anchors in Tension using Neural Networks," *Advances in Engineering Software*, 36, p. 87–97.
- Flood, I., Kartam, N. 1994. "Neural Network in Civil Engineering I: Principles and Understandings," *ASCE J. Comput. Civil Eng.*, 8(2), p. 131–148.
- Kewalramani, M.A., Gupta, R. 2006. "Concrete Compressive Strength Prediction using Ultrasonic Pulse Velocity through Artificial Neural Networks," *Automation in Construction*, 15, p. 374–379.
- Rajagopalan, P.R., Prakash, J., Naramimhan, V. 1973. "Correlation Between Ultrasonic Pulse Velocity and Strength of Concrete," *Indian Concrete Journal*, 47(11), p. 416–418.
- Bilgehan, M. 2010. "A Comparative Study for the Concrete Compressive Strength Estimation using Neural Network and Neuro-Fuzzy Modelling Approaches," *Nondestructive Testing and Evaluation*, Doi:10.1080/10589751003770100.
- Bilgehan, M., Turgut, P. 2010. "Artificial Neural Network Approach to Predict Compressive Strength of Concrete through Ultrasonic Pulse Velocity," *Research in Nondestructive Evaluation*, 21, 1-17.
- Bilgehan, M., Turgut, P. 2010. "The Use of Neural Networks in Concrete Compressive Strength Estimation," *Computers and Concrete*, 7(3), p. 271-283.
- Yenigün, K., Bilgehan, M., Gerger, R., Mutlu, M. 2010. "A Comparative Study on Prediction of Sediment Yield in the Euphrates Basin," *International Journal of Physical Sciences*, 5(5), p. 518-534.
- Karadağ, R. 2004. "Tavuk Üretim Çiftliklerinde Döşemenen ısıtmanın Analizi ve Verime Etkisi," *Doktora Tezi, Yıldız Teknik Üniversitesi*.
- www.fluent.com, 2001.
- Omri, M. N. 2006. "Galanis, Numerical Analysis of Turbulent Natural Convection in a Cavity," the Thirteenth International Heat Transfer Conference, Sydney, Australia, p. NCV-08.
- Rumelhart, D.E., Hinton, G.E., Williams, R.J. 1986. *Learning Internal Representation by Error Propagation*. Inf: Parallel Distributed Processing (Ed. by Rumelhart, D.E. and McClelland, J.L.), vol. 1: Foundations, MIT Press, Cambridge, Massachusetts, USA.