



ISSN:1306-3111
e-Journal of New World Sciences Academy
2009, Volume: 4, Number: 3, Article Number: 1A0026

TECHNOLOGICAL APPLIED SCIENCES

Received: July 2008
Accepted: June 2009
Series : 2A
ISSN : 1308-7223
© 2009 www.newwsa.com

Betül Bektaş Ekici

U.Teoman Aksoy

Ömer Keleşoğlu

Firat University
bbektas@firat.edu.tr
Elazığ-Turkey

**BİNA ISITMA VE SOĞUTMA ENERJİSİ İHTİYAÇLARININ YAPAY SİNİR AĞI İLE
BELİRLENMESİ**

ÖZET

Bu çalışma, bina enerji ihtiyacı tahmininde kullanılabilen Yapay Sinir Ağı (YSA) tabanlı bir yöntem sunmaktadır. Bina ısıtma ve soğutma enerjisi ihtiyaçlarının tahmin edilmesinde; bina biçim faktörü, yönlenme açısı, yalıtım kalınlığı ve saydamlık oranı parametrelerinden yararlanılmıştır. Yapılan çalışmada, daha başarılı sonuçlar elde edildiği için Levenberg-Marquardt eğitim fonksiyonu ile oluşturulan geri yayımlı bir YSA yapısı tercih edilmiş ve veriler ağı normalize edilerek sunulmuştur. YSA'nın eğitimi ve test edilmesinde kullanılan veriler, tuğla duvar için Explicit sonlu fark metodu kullanılarak hesaplanmıştır. Sayısal uygulamalar, Elazığ yöresine ait gerçek iklimsel verileri kullanılarak FORTRAN programı ile gerçekleştirilmiştir. YSA uygulamaları ise MATLAB programı ile yapılmıştır. Çalışmada elde edilen YSA çıktıları sayısal sonuçlarla karşılaştırıldığında, YSA tabanlı tahmin uygulamasının %93-99 arasında değişen bir doğruluk oranı ile bina enerji ihtiyacını tahmin ettiği görülmüştür.

Anahtar Kelimeler: Isıtma ve Soğutma Enerjisi, YSA, Bina Enerji Tasarrufu, Isı Yalıtımı

**DETERMINATION OF BUILDING HEATING AND COOLING ENERGY NEEDS USING
ARTIFICIAL NEURAL NETWORK**

ABSTRACT

This paper presents the results of Artificial Neural Network (ANN) based study, which will be used in prediction of building energy requirement. Building heating and cooling requirements were estimated by benefitting building form factor, orientation angle, insulation thickness and transparency ratio parameters as inputs. Because of the successful results achieved, a backpropagation ANN structure with Levenberg Marquardt training function is preferred and data presented to network by being normalized. The data used for training and testing of ANN were calculated by using explicit finite difference method for a brick wall. The numerical applications were carried out in FORTRAN program by using real average climatic data of Elazığ region. ANN applications were done with MATLAB program. When the outputs obtained from ANN were compared with numeric results, it is seen that the ANN based application predicts the building energy requirements with the accuracy ratio varying between 93-99%.

Keywords: Heating And Cooling Energy, ANN, Building Energy Saving, Heat Insulation



1. GİRİŞ (INTRODUCTION)

1970'lerde yaşanan enerji krizinin ardından enerjinin etkin ve verimli kullanılması ile yenilenebilir enerji kaynakları konularında yapılan çalışmalar hız kazanmıştır. Fosil yakıtların hızla tükenmesi, maliyetlerinin artması ve kullanımı ile açığa çıkan atıkların görmezden gelinemeyecek seviyelere ulaşması, binaların enerji etkin olarak tasarlanmasını bir zorunluluk haline getirmiştir. Bir binanın enerji etkinliği; bina kabuğunun iç ortamın konfor koşullarını değiştiren dış çevreye ait tasarım parametrelerinden minimum seviyede etkilenecek ve bina kullanımı süresince gerekli olan ısıtma ve soğutma enerjisi ihtiyaçlarının minimum seviyede tutulabilmesini sağlayacak şekilde tasarlanması ile sağlanabilir.

Binaların enerji ihtiyaçları, dış ortam sıcaklığı ($^{\circ}\text{C}$), güneş ışınlama miktarı (W), rüzgâr hızı vb. gibi fiziksel çevreye ait parametreler ile saydamlık oranı, binanın biçim faktörü ve yönlendiği gibi yapay tasarım parametrelerinden doğrudan etkilenmektedir [1]. Henüz tasarım aşamasında, bu parametreleri göz önünde bulundurarak yapılacak bir ön çalışma ile daha az enerji tüketen binaların oluşturulması sağlanabilir. Bina dış bileşenlerinde gerçekleşen ısı kaybı ve kazançlarının sebep olduğu enerji tüketiminin azaltılmasıyla birlikte, ihtiyaç duyulacak enerji miktarında bir azalma olacak dolayısıyla da, bina kullanım maliyetinde bir düşme gerçekleşecektir [2]. Bu nedenle bina enerji ihtiyaçlarının önceden tahmini, bina işletmesinde günlük işlevlerinin optimizasyonu ve daha iyi kontrol stratejileri seçilmesi açısından önemli bir rol oynamaktadır. Böylelikle bina alt sistemlerinde en fazla enerji ihtiyacı gerektirecek olan etkenler belirlenecek ve bunların daha az enerji kullanarak gerekli konfor koşullarını yerine getirecek şekilde tasarlanması sağlanacaktır [3]. Kullandığı enerjinin büyük bir bölümünü dış alım yoluyla karşılayan Türkiye gibi ülkelerde enerji etkin tasarım anlayışının en kısa sürede yaygınlaşması gerekmektedir. Yenilenebilir enerji kaynaklarının kullanılabilmesi için gerekli altyapının olmadığı ve maliyetlerinin de fazla olduğu dikkate alınırsa binalarda enerji tasarrufu yoluna gidilmesi en doğru yol olacaktır.

Bina enerji ihtiyaçlarını belirleyebilmek için yapılacak olan bu ön çalışma, klasik yöntemlerle yapıldığında uzun süreli ve yorucu olabilmektedir. Mevcut paket programlar da uzun yılların ortalama iklimsel verilerine ve birtakım kabullere dayanarak hazırlandığından yeterli hassasiyeti gösterememektedir. Ancak gelişen teknoloji ile birlikte gündemdeki yerini daha da sağlamlaştıran akıllı sistem uygulamaları bu süreci kısaltmaktadır. Özellikle yaygın olarak kullanılan Yapay Sinir Ağları (YSA), pek çok farklı mühendislik probleminin çözümünde uygulanmış ve başarılı sonuçlar elde edilmiştir. Literatürde Ni ve Wang [4], çok katmanlı ileri beslemeli bir sinir ağını betonun 28 günlük basınç dayanımını tespit etmekte kullanmış, sinir ağı modellerinin betonun basınç dayanımı için pratik ve ileriye dönük bir araç olduğunu belirtmişlerdir. Singh ve diğ.[5], akıllı sistemlerden YSA ve UATBÇS (Uyarlamalı ağ tabanlı bulanık çıkarım sistemi) kullanımını destekleyen çalışmalarında, farklı eğitim fonksiyonları kullanarak kayaların ısı iletim değerlerini tahmin etmişlerdir. Park ve diğ.eri [6], sinir ağı tabanlı çalışmalarında, katılaştıran çimento hamurunda hidrasyon derecesi, ısı oranının evrimini bağıl nem ve toplam porozite gibi çimento sertleşme özelliklerinin tahminini yapmışlardır. Mohseni ve diğ. [7], dış ortam sıcaklığı, kullanılan elektrik gücü, günün saatleri, duvar sıcaklıkları vb. değişkenlerden yola çıkıp ileri beslemeli sinir ağı modeli yardımıyla oda ve bina etkin sıcaklığını tahmin edip, lineer ARX modellerinden daha başarılı sonuçlar elde etmişlerdir. Kalogirou ve Bojic [8], pasif bir güneş evinin enerji tüketimi tahmini için YSA



tabanlı bir simülasyon programı geliştirmiş ve % 99 oranında başarılı sonuçlara ulaşmışlardır. Keleşoğlu ve diğ. [9], çok katmanlı ileri beslemeli bir yapay sinir ağını yalıtım malzemesi kalınlığının tespit edilmesinde kullanmışlardır.

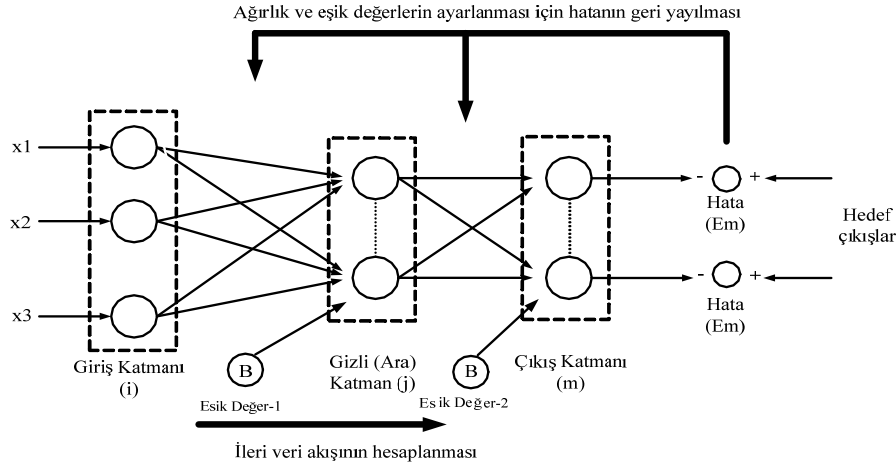
Yapılan bu çalışmada ise; belirtilen çalışmaların ışığında bina ısıtma ve soğutma enerjisi ihtiyaçlarının, binanın tasarımı aşamasında kısa sürede tespit edilip gerekli önlemlerin alınmasında YSA'nın kullanılabilirliği değerlendirilmiştir. Enerji ihtiyacı tahmini için oluşturulan YSA'nın eğitim setinde bina biçim faktörü, yönelme açısı, yalıtım kalınlığı ve saydamlık oranı parametreleri giriş olarak kullanılmış ve bina ısıtma ve soğutma enerjisi ihtiyaçları çıkış değerleri olarak alınmıştır. Elazığ iline ait iklimsel veriler Devlet Meteoroloji İşleri Genel Müdürlüğü'nden temin edilmiştir. Bina örneklerinin enerji ihtiyaçları FORTTRAN [10] ortamında hazırlanan bir bilgisayar programı kullanılarak hesaplanmıştır. YSA uygulamaları için ise MATLAB [11] programı kullanılmıştır.

2. ÇALIŞMANIN ÖNEMİ (RESEARCH SIGNIFICANCE)

Enerji etkin yapı tasarımı oldukça güncel bir konudur. Kısıtlı kaynakların etkin bir şekilde kullanılması ve yenilebilir enerji kaynaklarından mümkün oldukça yararlanabilmek adına bina tasarımında pasif tasarım parametrelerinin kullanılması gerekmektedir. Bu çalışmada ise, bu kaynaklardan optimum seviyede yararlanmayı sağlamak amacıyla tasarımın erken aşamalarında tasarımcı ve mühendislere referans olabilecek bir yapay zeka yöntemi sunulmaktadır.

3. YAPAY SİNİR AĞLARI (ARTIFICIAL NEURAL NETWORKS)

Enerji tahmininde yeni bir metot olan yapay sinir ağları, insan beyninin çalışma prensiplerini taklit ederek büyük doğrulukta sınıflandırma, tahmin işlevlerini gerçekleştirebilen bilgisayar programlarıdır. Bir kara kutu gibi çalışan bu programlar, sistem hakkında çok detaylı bilgiye ihtiyaç duymazlar. Gerekli olan bilgiyi giriş parametreleri ile kontrol edilen ve edilmeyen değişkenler arasındaki ilişkilere dair daha önceden kaydedilmiş olan verilerden yola çıkarak temin ederler. YSA'nın diğer tahmin modellerine göre sağlamış olduğu avantaj, değişkenleri arasında karmaşık ilişkiler olan problemleri modelleyebilmesidir [12]. Ağırlıklara sahip bağıntılarla her biri kendi hafızasına sahip işlem birimlerinden oluşan paralel ve dağıtılmış bilgi işleme yapıları olan YSA [13], çok sayıda birbirine bağlı proses elemanı olarak adlandırılan ve benzer karakteristiklere sahip giriş, sinaptik gerilim, aktivasyon, çıkış ve bias gibi nöron ve elemanlardan oluşur [5]. Bu proses elemanları arasında yer alan çok sayıdaki bağıntı, ağın ağırlıklarını taşımaktadır. Bir ağın eğitilmesi ağırlıkların, aktivasyon değişkenlerinin ve transfer fonksiyonlarının ayarlanması ile ağın istenilen fonksiyonu gerçekleştirebilmesi şeklindedir. Bu durum en açık şekilde Wang ve diğerleri [14], tarafından verilmiş Şekil 1'deki diyagram ile açıklanabilir.



Şekil 1. İleri beslemeli geri yayımlı bir sinir ağı mimarisi
 (Figure 1. The architecture of a feedforward backpropagation neural network)

Şekil 1'den de anlaşılacağı gibi ileri veri akışının hesaplanması için öncelikle örneklerin verilmesi, bir başka deyişle giriş katmanından ağa gösterilmesi gerekmektedir. Bu eğitim verileri, verilecek olan girişlere karşılık gelen çıkış değerlerini de içermelidir. Giriş katmanına gösterilen giriş değerleri hiçbir değişikliğe uğramadan 1 nolu eşitlikte görüldüğü gibi ara katmana gönderilirler. [15];

$$C_k^i = G_k \quad (1)$$

Burada G_k giriş katmanındaki k giriş katmanı elemanını, j ise ara katman elemanına bağlayan bağlantının ağırlık fonksiyonunu gösterir. İleri beslemeli ağın bağlantı ağırlıkları genel delta kuralının uygulanması ile eğitim veri kümesindeki giriş ve çıkış örneklerinden türetilir. j ara katman elemanının çıktısı ise, net girdinin etkinleştirme fonksiyonundan geçirilmesi ile hesaplanır. Etkinleştirme fonksiyonunun bu çalışmada olduğu gibi sigmoid fonksiyonu olması durumunda çıktılar [15];

$$C_j^a = \frac{1}{1 + e^{-(NET_j^a + \beta_j^a)}} \quad (2)$$

şeklinde olur. Burada β_j , ara katmanda bulunan j elemanına bağlanan eşik değer elemanının ağırlığını göstermektedir. Çıkış katmanındaki m . işlem elemanı için oluşan hata [15];

$$E_m = B_m - C_m \quad (3)$$

ile ifade edilir. Burada C_m ve B_m sırası ile ağa sunulan giriş için ağın ürettiği çıkış ile ağın beklenen çıkışlarıdır. Çıkış katmanı için oluşan toplam karesel hata (SSE) ise [13];

$$SSE = \frac{1}{2} \sum_m (E_m)^2 \quad (4)$$

formülü ile bulunur. Ortalama karesel hata değeri olan MSE ise, toplam karesel hatanın örnek sayısına bölünmesiyle elde edilir [7].

$$MSE = SSE/N = \frac{1}{N} \sum_{m=1}^N \frac{1}{2} (E_m)^2 \quad (5)$$

Hata değerinin sıfıra yakınlığı, yapay sinir ağı tarafından hesaplanan çıkışların beklenen çıkışlarla uyduğunu ve ağın iyi eğitildiğini göstermektedir. Geri yayımlı eğitim başlangıçta tüm düğümlerde ağırlıklara rasgele değerler atayarak yapılır. Eğitim verileri her zaman ağa gösterilir ve her düğüm için etkileştirme fonksiyonu hesaplanır. Ara katmandaki j işlem elemanını, çıkış katmanındaki m işlem elemanına bağlayan bağlantının, t . iterasyonda ağırlığının değişim miktarı ΔA_a [15];

$$\Delta A_{jm}^a(t) = \lambda \delta_m \zeta_j^a + \alpha \Delta A_{jm}^a(t-1) \quad (6)$$

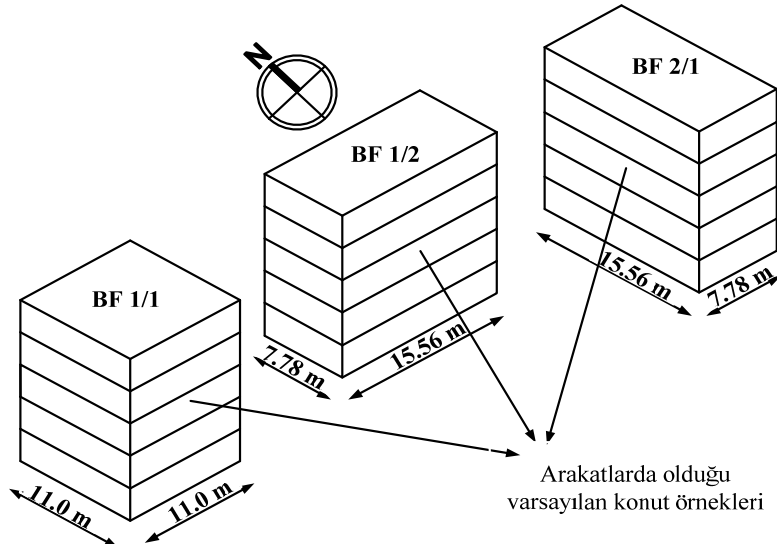
formülü ile hesaplanır. Burada λ öğrenme katsayısı, α momentum katsayısı ve δ_m ise m çıkış biriminin hatasını göstermektedir ve aşağıdaki eşitlik ile ifade edilir [15].

$$\delta_m = \zeta_m(1 - \zeta_m)E_m \quad (7)$$

4. VERİ KÜMELERİNİN OLUŞTURULMASI (THE DEVELOPMENT OF DATASETS)

Enerji ihtiyaçları incelenen binalar, Elazığ yöresinde bulunduğu varsayılan konut örnekleridir. Bina örnekleri, Şekil 2'de görüleceği gibi BF 1/2, BF1/1 ve BF 2/1 biçim faktörlerine ve aynı taban alanına (121 m²) sahiptir. Bina yüzey alanlarının %15, %20 ve %25 saydamlık oranına sahip olduğu durumlar göz önünde bulundurulmuştur. Şekil 3'de uygulama çalışmasında kabuk eleman olarak kullanılan yalıtımsız, 2.5, 5, 10 ve 15 cm kalınlıkta ısı yalıtımı uygulanmış duvar örnekleri görülmektedir. Bina alternatiflerinin 80°'ye kadar 10°'lik farklara sahip yüzey azimut açıları ile zemine oturtulduğu varsayılmıştır. Konut örneklerinin ara katlarda olduğu varsayılmış ve döşemelerden olan ısı geçişleri ihmal edilmiştir.

Tablo 1'den yararlanılarak oluşturulabilecek bina örneklerinden 225 adedi kullanılarak tahmin işlemi gerçekleştirilmiştir. Bu örneklerden önce 90 adedi kullanılarak ağı eğitilmiş, geri kalan ve daha önceden ağı gösterilmemiş olan 135 adet örnek ile de ağı test edilmiştir.



Şekil 2. Farklı biçim faktörlerine sahip bina örnekleri
(Figure 2. The building samples having different form factors)

Eğitim ve test verilerinin temini için yapılan sayısal hesaplamalar, Devlet Meteoroloji İşleri Genel Müdürlüğü'nden elde edilen Elazığ yöresine ait saatlik ortalama iklimsel veriler ile

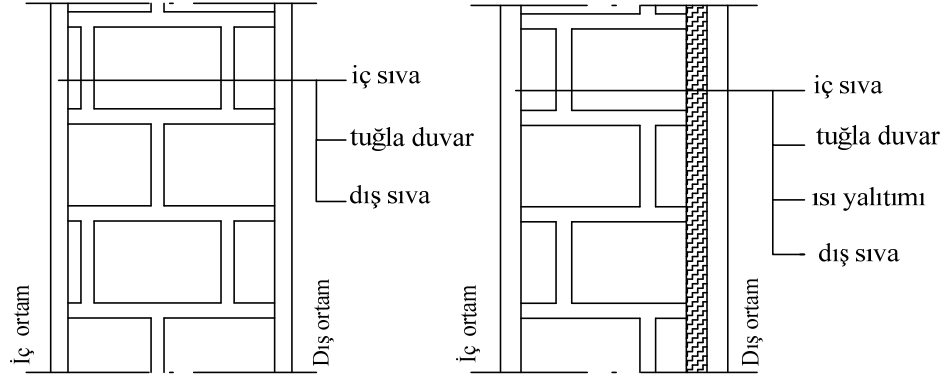


yapılmıştır. Bina kabuğundaki sıcaklık dağılımı, bir boyutlu geçici ısı iletimi koşulları göz önünde bulundurularak explicit sonlu fark yaklaşımı ile FORTRAN ortamında hazırlanan bir bilgisayar programı ile gerçekleştirilmiş ve YSA uygulamaları için MATLAB programı kullanılmıştır.

Tablo 1. Ağın eğitimi ve test edilmesi için oluşturulan bina senaryoları
(Table 1. The building scenarios developed for training and testing of the network)

| Saydamlık Oranı | Yalıtım Kalınlığı | Bina Biçim Faktörü | | | |
|-----------------|-------------------|--------------------|--------|--------|----|
| | | BF 1/2 | BF 1/1 | BF 2/1 | |
| %15 | 0 cm yalıtım | 0 | 0 | 0 | |
| | | 10 | 10 | 10 | |
| | | 20 | 20 | 20 | |
| %20 | | · | · | · | |
| | | · | · | · | |
| | | 70 | 70 | 70 | |
| %25 | | 80 | 80 | 80 | |
| | | 2.5 cm yalıtım | 0 | 0 | 0 |
| | | | 10 | 10 | 10 |
| 20 | | | 20 | 20 | |
| %20 | | | · | · | · |
| | | | · | · | · |
| | 70 | | 70 | 70 | |
| %25 | 80 | | 80 | 80 | |
| | 5 cm yalıtım | | 0 | 0 | 0 |
| | | | 10 | 10 | 10 |
| 20 | | | 20 | 20 | |
| %20 | | | · | · | · |
| | | | · | · | · |
| | | 70 | 70 | 70 | |
| %25 | | 80 | 80 | 80 | |
| | | 10 cm yalıtım | 0 | 0 | 0 |
| | | | 10 | 10 | 10 |
| 20 | | | 20 | 20 | |
| %20 | | | · | · | · |
| | | | · | · | · |
| | 70 | | 70 | 70 | |
| %25 | 80 | | 80 | 80 | |
| | 15 cm yalıtım | | 0 | 0 | 0 |
| | | | 10 | 10 | 10 |
| 20 | | | 20 | 20 | |
| %20 | | | · | · | · |
| | | | · | · | · |
| | | 70 | 70 | 70 | |
| %25 | | 80 | 80 | 80 | |

YSA, bu çalışmada çok sayıda değişkeni olan karmaşık bir problemin sayısal işlemlere gerek kalmadan çözülebilmesi ve daha çabuk sonuç elde edilebilmesi amacıyla kullanılmıştır. Önceki örneklerden faydalanarak öğrenme işlevini yerine getirebilmesi, çıkıştaki hatayı ağın tümüne geri yayarak tolere edebilmesi, gürültülü ve tamamlanmamış verileri bile kontrol altına alabilmesi ve lineer olmayan problemleri modelleyip, bir kere eğitildikten sonra farklı problemleri yüksek hızla tahmin edip, sınıflandırabilmesi bu yöntemin tercih edilmesinin başlıca sebeplerindendir.



Şekil 3. Yalıtımlı ve yalıtımsız duvar uygulamaları
Figure 3. Wall applications with and without insulation

Şekil 4'de bina örneklerinin enerji ihtiyacının belirlenmesinde kullanılan ağ yapısı verilmiştir. Önerilen yapay sinir ağı, giriş, gizli ve çıkış katmanları olmak üzere üç katmanlı bir yapıya sahiptir. Giriş katmanındaki her örnek dört adet özellikten oluşmaktadır. Bunlar bina biçim faktörü, yönelme açısı, yalıtım kalınlığı ve saydamlık oranıdır. Çıkışlar ise bina yıllık ısıtma ve soğutma enerjisi ihtiyacı değerleridir. Gizli katmandaki nöron sayısı bu çalışma için deneme yanılma yoluyla tespit edilmiş ve en yüksek doğrulukta tahmin sonuçları veren 40 adet olarak belirlenmiştir.



Şekil 4. Enerji ihtiyacı tahmini için oluşturulan ağ yapısı
Figure 4. The network structure formed for energy prediction

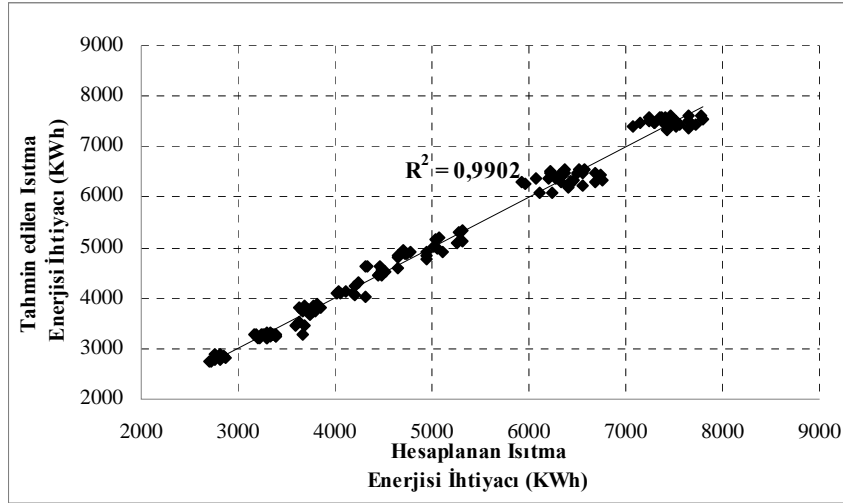
Çok katmanlı ağ, ileri beslemeli olup geriye yayılım algoritması kullanılmaktadır. Ağın eğitiminde, literatürde [16], de daha başarılı sonuçlar verdiği belirtilen Levenberg-Marquardt eğitim fonksiyonu kullanılmıştır. Giriş ve gizli katmanların transfer fonksiyonları tanjant sigmoid, çıkış katmanının transfer fonksiyonu ise lineer olarak belirlenmiştir. Ağın momentum katsayısı 0.2 ve öğrenme oranı %90 olarak seçilmiştir. Veriler ağa normalize edilerek sunulmuştur. Bütün veriler veri kümesindeki en büyük değere bölünerek [0-1] aralığında normalize edilmiştir.

5. BULGULAR VE DEĞERLENDİRME (FINDINGS AND EVALUATION)

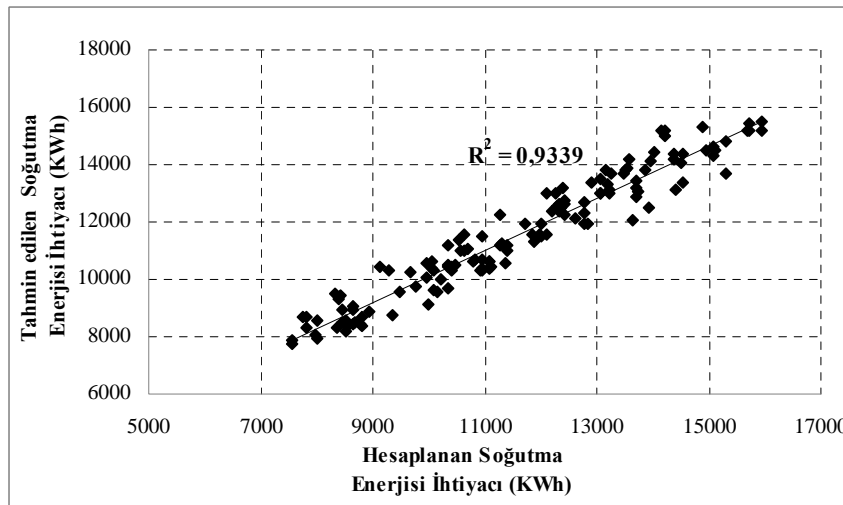
Bu çalışmada, enerji etkin bir bina tasarımı için YSA kullanılarak yapılabilecek bina yıllık ısıtma ve soğutma enerjisi ihtiyaçlarını önceden belirleyip, önemli ölçüde azaltabilecek bir yöntemin sonuçları sunulmuştur. Her bir bina türü için toplam 225 adet farklı örnekte elde edilen 4x90 veri YSA'nın eğitilmesi için, geriye

kalan 4x135 veri ise test edilmesi için kullanılmıştır. Bina örneklerine ait ısıtma enerjisi ihtiyaçları 2704 kWh ve 7817 kWh soğutma enerjisi ihtiyaçları ise sırasıyla 10486 kWh ve 20870 kWh değerleri arasındadır. Bina örneklerinin ısıtma ve soğutma enerjisi ihtiyaçlarına ait YSA çıkışları ve hesaplanan değerlerin karşılaştırmalı sonuçları sırasıyla Şekil 5 ve 6'da verilmiştir.

Ağın eğitilmesi ısıtma ve soğutma enerjisi ihtiyaçları için sırasıyla 592 ve 752 iterasyon sürmüştür. Ortalama karesel hata değerleri(MSE)ise 0.001 olarak belirlenmiş ve ağ performansı bu hata değerine ulaşınca ağın eğitimi kendiliğinden sona ermiştir. Sonuçların değerlendirilmesinde kullanılan çoklu bağıntı katsayısı değeri R^2 , bağımsız ve bağımlı değişkenler arasındaki ilişkinin bir ölçüsü olarak tanımlanmaktadır [17]. Çalışmanın sonuçlarına ait R^2 değerleri ısıtma enerjisi ihtiyacı için %99, soğutma enerjisi ihtiyacı için ise %93.3 olarak elde edilmiştir. Sonuçlara ait hata oranlarının ısıtma enerjisi ihtiyacı için ± 10 , soğutma enerjisi ihtiyacı için ise yaklaşık olarak -11,+14 aralığında olduğu Şekil 7-8'de görülmektedir.




Şekil 5. Isıtma enerjisi ihtiyacı çıkışlarının karşılaştırılması
(Figure 6. The comparison of the heating energy need outputs)




Şekil 6. Soğutma enerjisi ihtiyacı çıkışlarının karşılaştırılması
(Figure 6. The comparison of the cooling energy need outputs)



Önerilen sistemin güvenilirliği, çok sayıda bina örneğinden oluşturulmuş bir veri tabanına sahip olmasıdır. 135 adet test verisine ısıtma ve soğutma enerjisi ihtiyaçları da ayrı ayrı göz önünde bulundurulursa 270 adet veriye ortalama % 93-99 oranlarında doğru sonuçlar veren bir ağ, enerji etkin bina tasarımında mimar ve tesisat mühendislerine yardımcı olacak önemli bir araç konumundadır.



Şekil 7. Isıtma enerjisi ihtiyacı çıkışlarının hata oranları
(Figure 7. The error ratios of the heating energy needs outputs)



Şekil 8. Soğutma enerjisi ihtiyacı çıkışlarının hata oranları
(Figure 8. The error ratios of the cooling energy needs outputs)



6. SONUÇLAR (RESULTS)

Binalarda kullanılan enerji miktarı toplam enerji tüketimi içerisinde %40 oranında önemli bir yer teşkil etmektedir. Bu oranda bir tüketim enerji yönünden büyük ölçüde dışa bağımlı bir ülke olan Türkiye için oldukça fazladır. Bu nedenle yeni inşa edilecek binalarda enerji etkinliğin sağlanması gerekmektedir. Enerji etkin bir bina tasarlanırken binanın ihtiyacı olan enerji miktarını yaklaşık olarak önceden bilmek son derece önemlidir. Enerji konusundaki sıkıntıların arttığı son zamanlarda, yenilenebilir enerji kaynaklarının kullanımı ya da enerji tüketiminin minimize edilmesi kaçınılmazdır.

Yapılan çalışmada oluşturulan bina örneklerinin ısıtma ve soğutma enerjisi ihtiyaçlarını önceden tahmin etmek için çok katmanlı geri beslemeli bir yapay sinir ağı modeli kullanılmıştır. Ağ girişi olarak bina enerji ihtiyacını doğrudan etkileyen yapay tasarım parametrelerinden biçim faktörü, yönlenme açısı, saydamlık oranı ve yalıtım kalınlığı değerleri kullanılmıştır. Hesaplamaların karmaşık sayısal yaklaşımlarla yapılabilmesi mümkün olsa da, YSA'nın karmaşık problemleri daha hızlı ve basit bir şekilde modelleyebilmesi bu tekniğin en önemli avantajıdır. Hesaplanan değerlerle, YSA'nın verdiği sonuçlar kıyaslandığında ısıtma ve soğutma enerjisi ihtiyaçları için ortalama %93-99 arasında başarılı tahminler yaptığı görülmektedir. Sonuç olarak YSA uygulamalarının, bina ısıtma ve soğutma enerjisi ihtiyacı tahmininde büyük ölçüde faydalı olacağı açıktır.

KAYNAKLAR (REFERENCES)

1. Ak, F., (1993). Enerji etkin konut ve yerleşim birimi dizaynında uygulanabilecek bir yaklaşım, Yüksek Lisans Tezi, İstanbul: İstanbul Teknik Üniversitesi Fen Bilimleri Enstitüsü.
2. Çetiner, İ., (2002). Çift kabuk cam cephelerin enerji ve ekonomik etkinliğinin değerlendirilmesinde kullanılabilecek bir yaklaşım, Doktora Tezi. İstanbul: İstanbul Teknik Üniversitesi Fen Bilimleri Enstitüsü.
3. Yang, J., Rivard, H., and Zmeurenau, R., (2005). On-line building energy prediction using adaptive artificial neural Networks. Energy and Buildings, vol:37, pp:1250-1259.
4. Ni, H.-G. and Wang, J.-Z., (2000). Prediction of compressive strength of concrete by neural networks. Cement and Concrete Research, vol:30, pp:1245-1250.
5. Singh, T. N., Sinha, S., and Singh, V.K., (2007). Prediction of thermal conductivity of rock through physico-mechanical properties. Building and Environment, vol:42, pp:146-155.
6. Park, K.-B., Noguchi, T., Plawsky, J., (2005). Modeling of hydration reactions using neural networks to predict the average properties of cement paste. Cement and Concrete Research, vol:35, pp:1676-1684.
7. Mohseni, M.S., Thomas, B., and Fahlén, P., (2006). Estimation of operative temperature in buildings using artificial neural networks, Energy and Buildings, vol:38, pp:635-640.
8. Kalogirou, S.A. and Bojic, M., (2000). Artificial neural networks for the prediction of the energy consumption of a passive solar building. Energy, vol:25, pp:479-491.
9. Keleşoğlu, Ö., Ekinçi, C.E., and Fırat, A., (2005). The using of artificial neural networks in insulation computations, Sigma, cilt:3, ss.58-66.
10. Sun Microsystems Inc. (2001). Fortran User's Guide.
11. Demuth H., Beale M., M. Hagan. 2006. Neural Network Toolbox 5. User's
12. Guide. The Mathworks, inc. 8, pp:9-16.



13. González, P. A. and Zammareno, J.M., (2005). Prediction of hourly energy consumption in buildings based on a feedback artificial neural network. *Energy and Buildings*, vol:37, pp:595-601.
14. Elmas, Ç., (2003). *Yapay Sinir Ağları (Kuram, Mimari, Eğitim, Uygulama)*. Ankara: Seçkin Yayıncılık, ISBN 975-34-76-12-4.
15. Wang, J.-Z., Ni, H.-G., He, J.-Y., (1999). The Application of automatic acquisition of knowledge to mix design of concrete. *Cement and Concrete Research*, vol: 29, pp:1875-1880.
16. Öztemel, E., (2003). *Yapay Sinir Ağları*. İstanbul: Papatya Yayıncılık, ISBN 975-67-97-39-8.
17. Hoekstra A., (1998). *Generalization in feed-forward neural classifiers*. PhD Thesis. Delft/Holland: Delft University of Technology.
18. İnternet, Middle Tennessee State University. Erişim adresi: <http://mtsu32.mtsu.edu:11308/regression/level3/multicorrel/index.htm> Erişim tarihi:15.03.2009.