

YAPAY SİNİR AĞLARI İLE TÜRKİYE ELEKTRİK ENERJİSİ TÜKETİMİNİN 2010 YILINA KADAR TAHMİNİ

Coşkun HAMZAÇEBİ ve Fevzi KUTAY

Endüstri Mühendisliği Bölümü, Mühendislik Mimarlık Fakültesi, Gazi Üniversitesi Maltepe, Ankara,
hamzacebi@gazi.edu.tr, fkutay@gazi.edu.tr

ÖZET

Bu çalışmada, uzun dönemli elektrik enerjisi tüketimi tahmininde yapay sinir ağlarının kullanılması araştırılmıştır. Yapay sinir ağları teknikleri ile bulunan sonuçlar, Box-Jenkins modelleri ve regresyon tekniği ile karşılaştırılmıştır. Bulunan sonuçlar yapay sinir ağlarının elektrik enerjisi tüketiminde iyi bir tahmin aracı olduğunu göstermiştir.

Anahtar Kelimeler: Yapay sinir ağları, Box-Jenkins, geri yayılım algoritması, regresyon.

ELECTRIC CONSUMPTION FORECASTING OF TURKEY USING ARTIFICIAL NEURAL NETWORKS UP TO YEAR 2010

ABSTRACT

This study is about using of artificial neural networks for long-term electric energy consumption forecasting. The results obtained by artificial neural networks are compared to those obtained by Box-Jenkins models and regression technique. It is shown that, artificial neural network is a good forecasting tool for forecasting of electric energy consumption.

Keywords: Artificial neural networks, Box-Jenkins, backpropagation algorithm, regression.

1. GİRİŞ

Elektrik enerjisi, üretim yerinden çok uzaklara dağıtım şebekeleri ile kolayca taşınabilen, dağıtımı kontrol altında tutulabilen, temiz bir enerji kaynağıdır.

Elektrik enerjisi sektörünün sağlıklı gelişimi için talep, arz, iletim, dağıtım ve fiyatlandırma konularında planlar yapılması büyük öneme sahiptir. Yapılacak planlama çalışmalarının en önemli sorunlarından biri, gelecekteki talep bilgileridir. Elektrik enerjisinin depolanamaması, talep tahminindeki doğruluk derecesinin önemini artırmaktadır. Yapılacak tahminler ne kadar doğru olursa, yapılan planlama çalışmalarının da o kadar geçerli olacağı açıktır.

Elektrik enerjisi tüketimi tahminine yönelik çalışmalar üç sınıfta değerlendirilebilir:

1. Kısa dönemli tahmin: saatlik, günlük veya haftalık.
2. Orta dönemli tahmin: aylık, üç aylık.

3. Uzun dönemli tahmin: yıllık veya daha uzun dönemler.

Yapılan bir çok çalışma geleceği tahminde, yapay sinir ağlarının (YSA) en az geleneksel metotlar kadar, hatta daha iyi neticeler verdiğini göstermiştir [1-3]. YSA'nın özellikle doğrusal olmayan zaman serilerinde gösterdiği başarı, bir tahmin aracı olarak tercih edilmesini sağlamıştır [4]. YSA'nın geleceği tahmin için kullanıldığı alanlardan biri de elektrik enerjisi talep tahminidir.

Kısa dönemli elektrik enerjisi talep tahmini için YSA'nın kullanıldığı bir çok çalışma mevcuttur. Park ve Sandberg [5] çalışmalarında, YSA'nın, kısa dönemli yük tahmininde, regresyon tabanlı tahmin tekniklerinden daha iyi sonuç verdiğini belirtmektedir. Peng vd. [6], kısa dönemli yük tahmini için değişik ağ alternatiflerini karşılaştırmışlardır. Liang ve Cheng [7], Tamimi ve Egbert [8], Dash vd. [9], kısa dönemli yük tahmini için bulanık sinir ağlarını kullanmışlardır. Srinivasan [10], genetik

algoritma ile geliştirilmiş YSA yardımı ile haftalık tahminde bulunmuştur. Kodogiannis ve Anagnostakis [11], Radyal Tabanlı Sinir Ağları, Dinamik Sinir Ağları, Bulanık Sinir Ağları ile Otoregresif (Auto Regressive-AR) modelleri karşılaştırmıştır.

Uzun dönemli elektrik enerjisi tüketimi tahmini için yapılmış bazı çalışmalar mevcuttur. Kermanshahi ve Iwamiya [12], Japonya için 2020 yılına kadar elektrik enerjisi tüketiminin tahmininde geri yayılım sinir ağlarını (backpropagation networks) ve Jordan geri beslemeli ağını kullanmışlardır. Al-Saba ve El-Amin [13], Suudi Arabistan için 1997-2006 tarihleri arasında gerçekleştirilecek en yüksek yük talebini tahmin etmeye çalışmışlardır. Parlos vd. [14], uzun dönemli yük tahmini için YSA, genetik algoritma (GA) ve bulanık mantığın (BM) beraber kullanıldığı melez bir model geliştirmişlerdir. Padmakumari vd. [15] uzun dönemli yük tahmini için, bulanık sinir ağları ile tahminde bulunmaya çalışmışlardır.

Bu çalışmada, Türkiye elektrik enerjisi tüketimi için günümüzden, 2010 yılına kadar uzun dönemli bir tahmin yapılmaya çalışılmıştır. Zaman serileri analizi teknikleri, regresyon tekniği ve yapay sinir ağları tahmin için kullanılmış ve hangi yöntemin daha iyi sonuç verdiği araştırılmıştır.

2. ZAMAN SERİLERİ ANALİZİ (ZSA)

Zaman serilerinde bir analiz ve tahmin yöntemi olan Box-Jenkins tekniği; kesikli, doğrusal stokastik süreçlere dayanır. Otoregresif (Auto Regressive-AR), Hareketli Ortalama (Moving Average - MA), Otoregresif - Hareketli Ortalama (Autoregressive-Moving Average - ARMA) ve Bütünlenen Otoregresif-Hareketli Ortalama (Autoregressive Integrated Moving Average - ARIMA), Box-Jenkins tahmin modelleridir. AR(p), MA(q) ve bunların birleşimi olan ARMA(p,q) modelleri durağan süreçlere uygulanırken, ARIMA(p,d,q) modelleri durağan olmayan süreçler için kullanılmaktadır. Bu çalışmada bilinen bu yöntemler için ayrıntılı bilgi verilmeyecektir. Detaylı bilgi Box ve Jenkins [16]'de bulunabilir.

2.1. AR(p) Modelleri

AR(p) modelinde Y_t değeri, serinin p dönem geçmiş değerlerinin ağırlıklı toplamının ve rassal hata teriminin doğrusal fonksiyonudur. AR(p) modelleri genel olarak aşağıdaki gibi gösterilir:

$$Y_t = \Phi_1 Y_{t-1} + \Phi_2 Y_{t-2} + \dots + \Phi_p Y_{t-p} + \delta + a_t \quad (1)$$

Burada $Y_{t-1}, Y_{t-2}, \dots, Y_{t-p}$ geçmiş gözlem değerleri, $\Phi_1, \Phi_2, \dots, \Phi_p$ geçmiş gözlem değerleri için katsayılar, δ bir sabit değer ve a_t de hata terimidir.

2.2. MA(q) Modelleri

MA(q) modelinde Y_t değeri, serinin geriye doğru q

dönem geçmiş hata terimlerinin ve ortalamasının doğrusal fonksiyonudur. MA(q) modelleri genel olarak aşağıdaki gibi gösterilir:

$$Y_t = \mu + a_t - \theta_1 a_{t-1} - \theta_2 a_{t-2} - \dots - \theta_q a_{t-q} \quad (2)$$

Burada $a_t, a_{t-1}, a_{t-2}, \dots, a_{t-q}$ hata terimlerini, $\theta_1, \theta_2, \dots, \theta_q$ hata terimleri ile ilgili katsayıları, μ sürecin ortalaması olan bir sabiti göstermektedir.

2.3. ARMA(p,q) Modelleri

ARMA modelleri en genel durağan stokastik süreç modelleri olup, geçmiş gözlemlerin ve geçmiş hata terimlerinin doğrusal bir fonksiyondur. ARMA(p,q) modelleri genel olarak aşağıdaki gibi gösterilebilir:

$$Y_t = \Phi_1 Y_{t-1} + \Phi_2 Y_{t-2} + \dots + \Phi_p Y_{t-p} + \delta + a_t + \theta_1 a_{t-1} - \theta_2 a_{t-2} - \dots - \theta_q a_{t-q} \quad (3)$$

Üç numaralı eşitlikte, $Y_{t-1}, Y_{t-2}, \dots, Y_{t-p}$ geçmiş gözlem değerlerini, $\Phi_1, \Phi_2, \dots, \Phi_p$ geçmiş gözlem değerleri için katsayıları, δ bir sabit değeri, $a_t, a_{t-1}, a_{t-2}, \dots, a_{t-q}$ hata terimlerini ve $\theta_1, \theta_2, \dots, \theta_q$ hata terimleri ile ilgili katsayıları temsil etmektedir.

2.4. ARIMA(p,d,q) Modelleri

Zaman serisinin durağan olduğu durumlarda, yani sürecin ortalamasının, varyansının ve kovaryansının zamana bağlı olarak değişmediği durumlarda ARMA(p,q) veya ARMA(p,q)'nın özel hali olan AR(p) veya MA(q) modellerinden uygun olanı kullanılabilir. Ancak gerçekte zaman serilerinin ortalama ve varyansında zamana bağlı olarak bir değişim olmaktadır. Bu durum durağan olmayan durum olarak adlandırılır. Bu tip zaman serileri durağan hale dönüştürüldüğünde yukarıda bahsedilen ARMA(p,q) modelleri tahmin için kullanılabilir. Zaman serisinin durağanlaştırılması ise fark almak suretiyle yapılır. Zaman serisinin doğrusal bir trendi var ise birinci fark serisi durağan olur. Eğer zaman serisinin eğrisel bir trendi var ise farkların tekrar farkı alınarak ikinci farklar serisi durağan olur. Bu durumda model, ARIMA(p,d,q) olarak ifade edilir. Burada "d" serinin durağanlaştırma (fark alma) parametresidir.

3. Yapay Sinir Ağları

İnsan beyin fonksiyonundan esinlenen yapay sinir ağları (YSA), deneme yolu ile öğrenme ve genelleştirme yapabilmektedir. YSA'nın kullanıldığı önemli alanlardan biri de geleceği tahmindir. YSA, veriler arasındaki bilinmeyen ve fark edilmesi güç ilişkileri ortaya çıkartabilir. YSA doğrusal değildir. Doğrusal modeller, önemli detayları anlayabildikleri ve açıklayabildikleri takdirde avantajlı olabilirler. Ancak ilgilenilen problemin temelindeki ilişki doğrusal olmadığı durumlarda doğrusal modeller uygun değildir [4].

YSA, girdi ve çıktı değişkenleri arasındaki herhangi bir ön bilgiye ihtiyaç duymadan, herhangi bir varsayımda bulunmadan, doğrusal olmayan modellemeyi sağlayabilmektedir [17]. Ağa, girdi bilgileri ve bu girdilere karşılık gelen çıktı bilgileri verilmekte ve ağın girdi-çıkıtı arasındaki ilişkiyi öğrenmesi sağlanmakta, böylece ağın eğitimi gerçekleştirilmektedir. Öğreticili öğrenme olarak adlandırılan bu yöntem genelde tercih edilen bir yöntemdir [18]. Öğreticili öğrenme yöntemi ile eğitilen iki ağ yapısı (Geri Yayılım Ağları ve Radyal Tabanlı Ağlar), mevcut problemin çözümünde kullanılacaktır.

3.1. Geri Yayılım Algoritması ve İleri Beslemeli Ağlar

Geri yayılım ağları (Back Propagation Networks-BPN) sıklıkla kullanılan bir ağ yapısıdır. Standart geri yayılım algoritması, ağ ağırlıklarının, performans fonksiyonunun negatif gradyanı yönünde ilerlediği gradyan iniş algoritmasıdır. Bir çok çeşidi olan geri yayılım algoritması, gradyan iniş ve newton metodu gibi standart optimizasyon tekniklerine dayanmaktadır.

Geri yayılım algoritması, birbirinden bağımsız olarak ilk defa Werbos [19] ve daha sonra Rumelhart [20] tarafından önerilmiştir. 1986 yılında Rumelhart ve arkadaşlarının geri yayılım algoritmasını yeniden keşfetmeleri, algoritmanın tanınmasını ve yaygın kullanılmasını sağlamıştır. Geri yayılım algoritması, en çok kullanılan öğreticili öğrenme algoritmasıdır.

İleri beslemeli ağlar girdiden çıktıya doğru tek yönde ilerlemeye müsaade etmektedir. Bu geri beslemelerin olmadığı anlamına gelmektedir. Tipik bir ileri beslemeli YSA, girdi katmanı, genellikle bir veya iki ara katman (gizli katman) ve çıktı katmanından oluşmaktadır. Her katmanda ilgilenilen probleme göre değişen sayıda nöronlar (sinir hücreleri)

bulunmaktadır [4,17]. Şekil 1'de tek gizli katmanlı ileri beslemeli bir YSA görülmektedir. Girdi katmanında n, gizli katmanda p ve çıktı katmanında m adet nöron bulunmaktadır. Her bir katmandaki nöronlar arasındaki bağlantıların ağırlıklarının düzenlenmesi ile ağın eğitimi gerçekleştirilir.

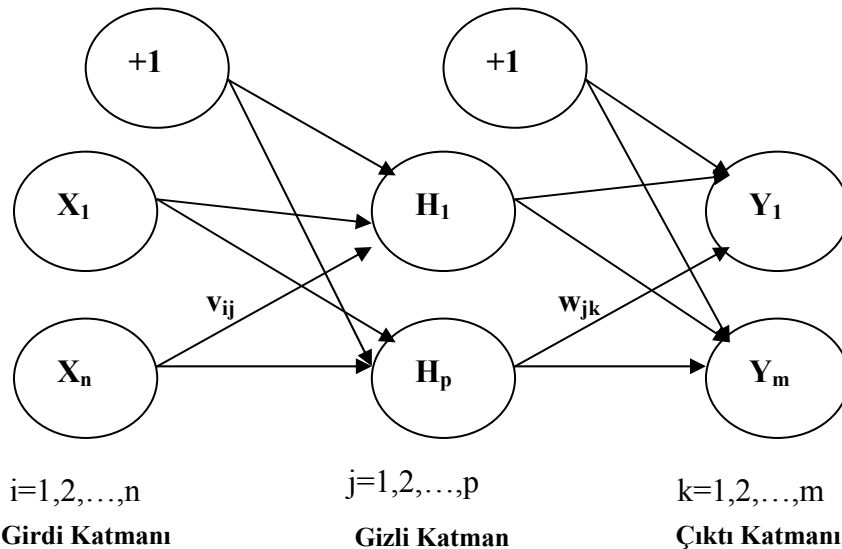
Ağırlıkların düzenlenmesi işlemi,

$$E = \frac{1}{2} \sum_{k=1}^m (y_k - t_k)^2 \quad (4)$$

hata fonksiyonunun minimize edilmesi ile sağlanmaktadır. Hata fonksiyonundaki, y_k , ağın ürettiği çıktıyı, t_k , arzu edilen çıktı değerini göstermektedir. $\frac{1}{2}$ sabit bir katsayıdır ve fonksiyon türevini kolaylaştırmak için eklenmektedir. Geri yayılım algoritması ismini, çıktı katmanında oluşan hatayı minimize etmek için geriye doğru ağırlıkların düzenlenmesi işleminden almaktadır. Algoritmanın matematiksel temeli burada anlatılmayacaktır. Detaylı bilgi için Haykin [18]'e bakılabilir.

3.2. Radyal Tabanlı Fonksiyon Ağları

Radyal tabanlı fonksiyon ağları (Radial Basis Function Networks-RBFN), çok boyutlu uzayda eğri uydurma yaklaşımıdır. RBFN'nin eğitimi, çok boyutlu uzayda eğitim verilerine en uygun bir yüzeyi bulma problemidir. RBFN, yapı olarak BPN ile benzerdir. Girdi katmanı, ara katman ve çıktı katmanından oluşur. Ara katmandaki radyal tabanlı aktivasyon fonksiyonu (gaus, üstel) girdileri dönüştürmeyi sağlar. Çıktı katmanında doğrusal bir aktivasyon fonksiyonu vardır [21]. RBFN'nin eğitimi, BPN'nin eğitiminden daha az bir zaman gerektirir. Ancak, BPN kadar doğru sonuçlar verebilmesi için daha fazla veriye ihtiyaç duymaktadır [22].



Şekil 1. İleri Beslemeli YSA

4. REGRESYON TEKNİĞİ

Regresyon Tekniği (RT), ölçülebilen bir veya daha fazla değişkenin, üzerinde etkili olduğu düşünülen başka bir değişkenle arasındaki ilişkinin modellenmesidir. Regresyon tekniğinde, etkileyen değişkenlere açıklayıcı değişken (bağımsız değişken), etkilenen değişkene de bağımlı değişken adı verilir. Regresyon modelleri doğrusal yada doğrusal olmayan modeller olarak sınıflandırılabilir. Ancak doğrusal olmayan modeller çeşitli yöntemlerle doğrusal modellere dönüştürülebilir. 5 ve 6 numaralı eşitlikler sırasıyla, tek bağımsız değişkenin olduğu doğrusal ve karesel regresyon modellerini göstermektedir.

$$Y = b_0 + b_1X + \varepsilon \quad (5)$$

$$Y = b_0 + b_1X + b_2X^2 + \varepsilon \quad (6)$$

$\varepsilon \sim N(0, \sigma^2)$, ε hata terimi, ortalaması sıfır, varyansı σ^2 olan Normal dağılıma sahip rassal değişkendir. X, bağımsız değişken vektörünü, Y bağımlı değişken vektörünü, b_0 sabit bir değeri, b_1 ve b_2 ilgili değişken için katsayıları göstermektedir.

5. UYGULAMA VE SONUÇLAR

Bu çalışmada MINITAB ve MATLAB Neural Network Toolbox yazılımları kullanılmıştır. Aşağıda sıralandığı şekilde bir uygulama gerçekleştirilmiştir:

- İlgili verilerin toplanması:
Geçmiş yıllara ait elektrik enerjisi tüketimi değerleri ve nüfus bilgileri[23,24]. Çalışmada, elektrik enerjisi tüketimi için anılan bütün değerler (gerçek değerler ve tahmin değerleri) GigaWatt – hour (GWh) birimle ifade edilmiştir.
- Verilerin eğitim, doğrulama ve test kümelerine ayrılması:
YSA için, 1970-1990 verileri eğitim, 1991-1998 verileri doğrulama ve 1999-2002 verileri test kümesi olarak kullanılmıştır. Diğer iki teknikte ise, 1970-1990 yılları verileri model belirleme aşaması için, 1991-1998 ve 1999-2002 verileri test amaçlı kullanılmıştır.
- Bahsedilen bütün teknikler için uygun modellerin

belirlenmesi, model çıktılarının üretilmesi.

- Test kümesinin tahmin sonuçları ile gerçek değerlerinin, geleneksel metotlar ve YSA için karşılaştırılması, hangi yöntemin daha az hata ile tahminde bulunduğu belirlenmesi,
- 2010 yılına kadar tahmin değerlerinin bulunması.

5.1. ARIMA Modelleri İçin Sonuçlar

ARIMA modellerinin belirlenmesi, ilgilenilen serinin otokorelasyon ve kısmi otokorelasyon fonksiyonları yardımı ile gerçekleştirilir. 1970-1990 yılları arasındaki veriler kullanılarak, uygun modeller araştırılmıştır. Belirlenen modeller ile 1991-1998 yıllarına ait tüketim değerleri tahmin edilmiştir. Bulunan tahmin değerleri, bu yıllara ait gerçek değerlerle karşılaştırılmış ve her model için mutlak yüzde hata (MYH) ve ortalama mutlak yüzde hata (OMYH) hesaplanmıştır. Tablo 1, bu karşılaştırmaya ait sonuçları göstermektedir. Tablo 1’de görüldüğü gibi, ilgili seri için, ARIMA(1,1,0)=ARI(1,1), ARIMA(2,2,0)=ARI(2,2), ARIMA(0,1,1)=IMA(1,1) ARIMA(0,2,1)=IMA(2,1) modelleri uygulanmıştır.

5.2. YSA İçin Sonuçlar

Tahmin problemleri için tasarlanan bir YSA, kuruluş yapısına göre, doğrusal olmayan regresyon modeli veya doğrusal olmayan otoregresif model olarak eğitilebilir ve sonuç üretebilir. Mevcut problem için kurulan YSA, doğrusal olmayan bir regresyon modeli görevi görmektedir ve aşağıda sıralanan alternatiflere göre sonuçlar bulunmuştur:

- **Model 1:** Girdi vektörü yıllar ve çıktı vektörü tüketim miktarı (BPN)
- **Model 2:** Girdi vektörü yıllar ve çıktı vektörü tüketim miktarı (RBFN)
- **Model 3:** Girdi vektörü nüfus ve çıktı vektörü tüketim miktarı (BPN)
- **Model 4:** Girdi vektörü nüfus ve çıktı vektörü tüketim miktarı (RBFN)

Kurulan geri yayılım ağının (BPN) tasarımı şu şekilde yapılmıştır: girdi ve çıktı katmanlarında bir adet nöron

Tablo 1. ARIMA modelleri ile 1991-1998 tahminleri

| YIL | GERÇEK (GWh) | TAHMİN (GWh) | | | | MYH (%) | | | |
|------|--------------|---------------|---------------|---------------|---------------|---------------|---------------|---------------|---------------|
| | | ARIMA (0,1,1) | ARIMA (1,1,0) | ARIMA (2,2,0) | ARIMA (0,2,1) | ARIMA (0,1,1) | ARIMA (1,1,0) | ARIMA (2,2,0) | ARIMA (0,2,1) |
| 1991 | 50295,7 | 52864,2 | 53459,4 | 53102,8 | 53247,1 | 5,1068 | 6,2902 | 5,5812 | 5,8681 |
| 1992 | 54613,1 | 55014,8 | 57748,3 | 57295,8 | 58046,9 | 0,7355 | 5,7407 | 4,9122 | 6,2875 |
| 1993 | 60406,3 | 57165,4 | 61617,9 | 62685,1 | 63033,1 | 5,3652 | 2,0058 | 3,7725 | 4,3486 |
| 1994 | 61420,3 | 59316 | 65160,2 | 67954,7 | 68205,7 | 3,4261 | 6,089 | 10,639 | 11,047 |
| 1995 | 67092,3 | 61466,6 | 68447,1 | 72971,5 | 73564,5 | 8,385 | 2,0193 | 8,7629 | 9,6467 |
| 1996 | 74326,8 | 63617,2 | 71534,4 | 78610,3 | 79109,7 | 14,409 | 3,7569 | 5,7631 | 6,435 |
| 1997 | 81884,9 | 65767,8 | 74465,9 | 84446,8 | 84841,3 | 19,683 | 9,0603 | 3,1287 | 3,6104 |
| 1998 | 87704,6 | 67918,4 | 77275,8 | 90195,6 | 90759,2 | 22,56 | 11,891 | 2,8402 | 3,4828 |
| | | | | | OMYH: | 9,9588 | 5,8566 | 5,6749 | 6,3408 |

kullanılmıştır. Tek gizli katman kullanılmıştır ve bu gizli katmanda bir nöron vardır. Gizli katman aktivasyon fonksiyonu hiperbolik tanjant fonksiyonudur. Çıktı katmanı aktivasyon fonksiyonu doğrusal bir fonksiyondur. Öğrenme oranı ve momentum katsayısı için 0.5 değeri alınmıştır. Öğrenme metodu olarak Powell-Beale algoritması kullanılmıştır. MATLAB Neural Network Toolbox'ında mevcut farklı öğrenme metotları ile de problem çözülmüş, ancak Powell-Beale algoritmasının daha iyi sonuç vermesi tercih edilmesini sağlamıştır.

Ağın eğitimi için, 1970-1990 verileri eğitim kümesi ve 1991-1998 verileri de doğrulama kümesi olarak kullanılmıştır. Ağ 10 defa çalıştırılarak, doğrulama kümesi için en iyi sonucu veren ağ yapısı bulunmuştur. En iyi ağ yapısı kullanılarak test kümesi tahmin değerleri üretilmiştir. Eğitim seti için, algoritmanın her bir çalıştırmada bulduğu hata kareleri ortalaması (MSE-Mean Squared Error) değerleri, 0.0031 – 0.0035 arasında değişmektedir. Algoritmanın sonlanması her bir çalıştırmada 50 -75 devir (epoch) arasında değişmektedir.

Bir diğer YSA modeli olan RBFN için de, bir girdi ve bir çıktı nöronu kullanılmıştır. Gizli nöron sayısı için en iyi değeri program kendisi bulmaktadır.

Model 1 ve 2 için bulunan sonuçlar ve ilgili OMYH değerleri Tablo 2'de verilmiştir. Model 3 ve 4'e göre bulunan değerler Tablo 3'te gösterilmiştir.

Tablo 2. Model 1 ve 2 için tahmin değerleri ve OMYH

| YIL | GERÇEK (GWh) | TAHMİN (GWh) | | MYH (%) | |
|------|--------------|--------------|-------|---------------|---------------|
| | | BPN | RBFN | BPN | RBFN |
| 1991 | 50295,7 | 50495 | 50068 | 0,3962 | 0,4527 |
| 1992 | 54613,1 | 54477 | 54491 | 0,2492 | 0,2235 |
| 1993 | 60406,3 | 58663 | 59237 | 2,8859 | 1,9357 |
| 1994 | 61420,3 | 63045 | 64277 | 2,6452 | 4,6510 |
| 1995 | 67092,3 | 67609 | 69574 | 0,7701 | 3,6989 |
| 1996 | 74326,8 | 72342 | 75077 | 2,6703 | 1,0093 |
| 1997 | 81884,9 | 77226 | 80728 | 5,6895 | 1,4128 |
| 1998 | 87704,6 | 82239 | 86459 | 6,2318 | 1,4202 |
| | | OMYH: | | 2,6923 | 1,8505 |

5.3. Regresyon Tekniği İçin Sonuçlar

Bu bölümde, yılların ve nüfus bilgisinin bağımsız değişken ve elektrik enerjisi tüketiminin bağımlı değişken olduğu iki ayrı seçenek için, 1970-1990 yıllarına ait veriler kullanılarak regresyon modelleri elde edilmiştir. İlgilenilen elektrik enerjisi tüketimi

Tablo 5. ZSA, RT ve YSA tekniklerinin OMYH için karşılaştırması

| ARIMA (0,1,1) | ARIMA (1,1,0) | ARIMA (2,2,0) | ARIMA (0,2,1) | RT | BPN | RBFN |
|---------------|---------------|---------------|---------------|--------|--------|--------|
| 9,9588 | 5,8566 | 5,6749 | 6,3408 | 5,9329 | 2,6923 | 1,8505 |

Tablo 3. Model 3 ve 4 için tahmin değerleri ve OMYH

| YIL | GERÇEK (GWh) | TAHMİN (GWh) | | MYH (%) | |
|------|--------------|--------------|-------|---------------|---------------|
| | | BPN | RBFN | BPN | RBFN |
| 1991 | 50295,7 | 49353 | 50262 | 1,8743 | 0,0670 |
| 1992 | 54613,1 | 53647 | 55558 | 1,7689 | 1,7301 |
| 1993 | 60406,3 | 58719 | 61694 | 2,7932 | 2,1317 |
| 1994 | 61420,3 | 62186 | 65697 | 1,2466 | 6,9630 |
| 1995 | 67092,3 | 65891 | 69731 | 1,7905 | 3,9329 |
| 1996 | 74326,8 | 69829 | 73699 | 6,0513 | 0,8446 |
| 1997 | 81884,9 | 74013 | 77526 | 9,6133 | 5,3232 |
| 1998 | 87704,6 | 81498 | 83363 | 7,0767 | 4,9502 |
| | | OMYH: | | 4,0269 | 3,2428 |

(ET) serisi için farklı regresyon modelleri denenmiş ve yıl faktörünün bağımsız değişken alındığı durumda karesel bir regresyon modelinin, nüfus faktörünün bağımsız değişken alındığı durumda ise, faktörlerin doğal logaritmalarının alınmasından sonra doğrusal bir regresyon modelinin uygun olduğu görülmüştür. Bulunan modeller aşağıdadır:

$$ET = 261311864 - 265794 \cdot yıl + 67,5904 \cdot yıl^2 \quad (7)$$

$$\log(ET = -13,4101 + 3,80871 \cdot \log(nüfus)) \quad (8)$$

Eşitlik 7 ve 8'deki regresyon modellerine göre 1991-1998 yılları için bulunan tahmin, MYH ve OMYH değerleri, Tablo 4'te verilmiştir.

Tablo 4. RT için tahmin değerleri ve OMYH

| YIL | GERÇEK (GWh) | TAHMİN (GWh) | | MYH (%) | |
|------|--------------|--------------|-------------|---------------|---------------|
| | | Yıllara Göre | Nüfusa Göre | Yıllara Göre | Nüfusa Göre |
| 1991 | 50295,7 | 49830,42 | 50622,59 | 0,9250 | 0,6499 |
| 1992 | 54613,1 | 53248,99 | 53698,40 | 2,4977 | 1,6748 |
| 1993 | 60406,3 | 56802,73 | 56924,62 | 5,9655 | 5,7637 |
| 1994 | 61420,3 | 60491,65 | 60318,50 | 1,5119 | 1,7938 |
| 1995 | 67092,3 | 64315,76 | 63863,32 | 4,1383 | 4,8127 |
| 1996 | 74326,8 | 68275,05 | 67622,22 | 8,1420 | 9,0204 |
| 1997 | 81884,9 | 72369,51 | 71585,45 | 11,6204 | 12,5779 |
| 1998 | 87704,6 | 76599,16 | 75758,35 | 12,6623 | 13,6210 |
| | | OMYH: | | 5,9329 | 6,2393 |

5.4. Karşılaştırma

Tahmin aracı olarak kullandığımız ZSA, YSA ve RT tekniklerinin karşılaştırılması Tablo 5 ve Tablo 6'da verilmiştir. Veriler 1991-1998 yılları için bulunan değerleri göstermektedir. Tablo 5, ZSA ile yılların girdi vektörü/bağımsız değişken olarak kullanıldığı YSA ve RT için OMYH değerlerini, Tablo 6, nüfus değişkeninin girdi vektörü/bağımsız değişken olarak kullanıldığı YSA ve RT için OMYH değerlerini göstermektedir.

Tablo 6. YSA ve RT tekniklerinin OMYH için karşılaştırması

| BPN | RBFN | RT |
|--------|--------|--------|
| 4,0269 | 3,2428 | 6,2393 |

Her iki tabloda da görüleceği üzere en düşük OMYH değerlerini YSA teknikleri vermiştir. Ancak, YSA tekniğinde, 1991-1998 verileri doğrulama kümesi olarak yani en iyi ağ yapısının belirlenmesinde yardımcı olarak kullanılmıştır. Dolayısıyla 1991-1998 yılları için YSA tekniklerinin daha iyi sonuç vermesi beklenen bir durumdur. Hangi tekniğin daha iyi sonuç verdiği üzerine yorum yapabilmek için, test kümesi (1999-2002) OMYH değerlerinin incelenmesi daha doğru olacaktır. 1999-2002 yılları için, ZSA teknikleri ile bulunan tahmin değerleri ve OMYH oranları Tablo 7’de, YSA teknikleri ile bulunan sonuçlar Tablo 8’de ve RT ile bulunan sonuçlar Tablo 9’da verilmiştir.

Tablo 8. YSA teknikleri ile bulunan tahmin değerleri ve OMYH

| YIL | GERÇEK (GWh) | RBFN (GWh) | BPN (GWh) | MYH (%) | |
|--------------|--------------|------------|-----------|---------------|---------------|
| | | | | RBFN | BPN |
| 1999 | 91201,9 | 92197 | 87358 | 1,0910 | 4,2147 |
| 2000 | 98295,7 | 97863 | 92558 | 0,4402 | 5,8371 |
| 2001 | 97070 | 103370 | 97811 | 6,4901 | 0,7633 |
| 2002 | 102800 | 108650 | 103090 | 5,6906 | 0,2821 |
| OMYH: | | | | 3,4280 | 2,7743 |

Test kümesi için de en küçük OMYH değerini YSA tekniklerinin verdiği görülmektedir. Bu sonuçlar, kurulan YSA yapısının tahmin için kullanılabilirliğini göstermektedir. Tablo 10’da, bahsedilen bütün teknikler kullanılarak, 2003-2010 yılları için bulunan net ET tahminleri gösterilmiştir.

Tablo 7. ZSA teknikleri ile bulunan tahmin değerleri ve OMYH

| YIL | GERÇEK (GWh) | ARIMA (0,1,1) (GWh) | ARIMA (1,1,0) (GWh) | ARIMA (2,2,0) (GWh) | ARIMA (0,2,1) (GWh) | MYH (%) | | | |
|--------------|--------------|---------------------|---------------------|---------------------|---------------------|----------------|----------------|---------------|---------------|
| | | | | | | ARIMA (0,1,1) | ARIMA (1,1,0) | ARIMA (2,2,0) | ARIMA (0,2,1) |
| 1999 | 91201,9 | 70069 | 79991 | 96279 | 96863 | 23,1715 | 12,2923 | 5,5668 | 6,2072 |
| 2000 | 98295,7 | 72220 | 82632 | 102625 | 103154 | 26,5278 | 15,9352 | 4,4043 | 4,9425 |
| 2001 | 97070 | 74370 | 85215 | 109021 | 109631 | 23,3851 | 12,2128 | 12,3117 | 12,9401 |
| 2002 | 102800 | 76521 | 87753 | 115631 | 116294 | 25,5632 | 14,6371 | 12,4815 | 13,1264 |
| OMYH: | | | | | | 24,6619 | 13,7694 | 8,6911 | 9,3040 |

Tablo 10. 2003-2010 yılları için tahmin değerleri

| YIL | RBFN (GWh) | BPN (GWh) | RT (GWh) | ARIMA (0,1,1) (GWh) | ARIMA (1,1,0) (GWh) | ARIMA (2,2,0) (GWh) | ARIMA (0,2,1) (GWh) |
|------|------------|-----------|-----------|---------------------|---------------------|---------------------|---------------------|
| 2003 | 113610 | 108360 | 114462,63 | 78671 | 90255 | 122492 | 123144 |
| 2004 | 118180 | 113600 | 120863,91 | 80822 | 92730 | 129481 | 130180 |
| 2005 | 122290 | 118780 | 127457,55 | 82973 | 95184 | 136648 | 137402 |
| 2006 | 125880 | 123870 | 134243,55 | 85123 | 97620 | 144038 | 144811 |
| 2007 | 128890 | 128850 | 141221,91 | 87274 | 100044 | 151595 | 152406 |
| 2008 | 131300 | 133690 | 148392,64 | 89424 | 102457 | 159324 | 160187 |
| 2009 | 133070 | 138380 | 155755,74 | 91575 | 104863 | 167255 | 168155 |
| 2010 | 134180 | 142890 | 163311,20 | 93726 | 107262 | 175369 | 176309 |

Tablo 9. RT tekniği ile bulunan tahmin değerleri ve OMYH

| YIL | Gerçek (GWh) | TAHMİN (GWh) | | MYH (%) | |
|--------------|--------------|--------------|-------------|---------------|---------------|
| | | Yıllara Göre | Nüfusa Göre | Yıllara Göre | Nüfusa Göre |
| 1999 | 91201,9 | 90781,1 | 83127,6 | 0,4613 | 8,8531 |
| 2000 | 98295,7 | 96413,0 | 96019,9 | 1,9153 | 2,3151 |
| 2001 | 97070 | 102237,1 | 102444,8 | 5,3231 | 5,5370 |
| 2002 | 102800 | 108253,7 | 108907,3 | 5,3051 | 5,9410 |
| OMYH: | | | | 3,2512 | 5,6615 |

6. SONUÇ

Yaptığımız bu çalışma, YSA tekniklerinin bir tahmin aracı olarak kullanılabilirliğini ve oldukça iyi sonuç verdiğini göstermektedir. Regresyon tekniğinin ve Box-Jenkins modellerinin iyi sonuç vermesi, gözlem sayısı ile sıkı ilişkilidir. Box ve Jenkins, ARIMA modellerinde 70’in üzerinde gözlem ile çalışılması gerektiğini söylemektedirler [16].

YSA teknikleri ise daha az veri ile çalışmaya müsaade etmektedir. Ancak YSA teknikleri, kara kutu (black box) özelliği gösterdiklerinden bazen olumsuz sonuçlar üretebilirler [25]. Bu yüzden, tahmin aracı olarak kullandıklarında, geleneksel metotlar ile bulunan sonuçlar YSA tekniklerini desteklemede yardımcı olarak kullanılabilir. Problemin yapısına uygun kurulmuş bir ağ, iyi neticeler verecektir. Bundan dolayı incelenen probleme göre uygun ağ yapıları araştırılmalıdır.

KAYNAKLAR

- Hill, T., O’Connor, M., Remus, W., “Neural Networks Models for Time Series Forecasts”,

- Management Sciences**, Cilt 42, No 7,1082-1092, 1996.
2. Sharda, R., Patil, R.B., "Connectionist Approach to Time Series Prediction: An Empirical Test", **Journal of Intelligent Manufacturing**, Cilt 3, 317-323, 1992.
 3. Tang, Z., Almeida, C., Fishwick, P.A., "Time Series Forecasting Using Neural Networks vs Box-Jenkins Methodology", **Simulation**, Cilt 57, No 5, 303-310, 1991.
 4. Zhang, G., Patuwo, B.E., Hu, M.Y., "Forecasting with Artificial Neural Networks: The State of the Art", **Inter. Journal of Forecasting**, Cilt 14, 35-62, 1998.
 5. Park, J., Sandberg, I.W., "Universal Approximation Using Radial Basis Function Networks", **Neural Computation**, Cilt 3, 246-257, 1991.
 6. Peng, T.M., Hubele, N.F., Karady, G.G., "Advancement in the Application of Neural Networks for STLF", **IEEE Trans. on Power Sys.**, Cilt 7, No1, 250-257, 1992.
 7. Liang, R.H., Cheng, C.C., "Short-Term Load Forecasting by a Neuro-Fuzzy Based Approach", **Electrical Power and Energy Systems**, Cilt 24, 103-111, 2002.
 8. Tamimi, M., Egbert, R., "Short Term Electric Load Forecasting Via Fuzzy Neural Collaboration", **Electric Power Systems Research**, Cilt 56, 243-248, 2000.
 9. Dash, P.K., Satpathy, H.P., Liew, A.C., "A Real-Time Short-Term Peak and Average Load Forecasting System Using a Self-Organising Fuzzy Neural Network", **Engineering Applications of Artificial Intelligence**, Cilt 11, No 2, 307-316, 1998.
 10. Srinivisan, D., "Evolving Artificial Neural Networks for Short Term Load Forecasting", **Neurocomputing**, Cilt 23, 265-276, 1998.
 11. Kodogiannis, V.S., Anagnostakis, E.M., "A Study of Advanced Learning Algorithms for STLF", **Eng. App. of Artificial Intelligence**, Cilt 12, No 2, 159-173, 1999.
 12. Kermanshahi, B., Iwamiya, H., "Up to Year 2020 Load Forecasting Using Neural Nets", **Electrical Power and Energy Systems**, Cilt 24, 789-797, 2002.
 13. Al-Saba, T., El-Amin, I., "Artificial Neural Networks as Applied to Long-Term Demand Forecasting", **Artificial Intelligence in Engineering**, Cilt 13, 189-197, 1999.
 14. Parlos, A.G., Oufi, E., Muthusami, J., Patton A.D., Atiya A.F., "Development of an Intelligent Long-Term Electrical Load Forecasting System", **Intelligent System Applications to Power System Proceedings**, 288-292, 1996.
 15. Padmakumari, K., Mohandas, K.P., Thiruvengadam, S., "Long Term Distribution Demand Fore. Using Neuro Fuzzy Computations", **In. Jo. of Electrical Power and Energy Systems**, Cilt 21, No 5, 315-322, 1999.
 16. Box, G., Jenkins, M., **Time Series Analysis Forecasting and Control**, Holden Day Inc., California, 1976.
 17. Kaastra, I., Boyd, M., "Designing a Neural Network for Forecasting Financial and Economic Time Series", **Neurocomputing**, Cilt 10, 215-236, 1996.
 18. Haykin, S., **Neural Networks: A Comprehensive Foundation**, Prentice Hall, New Jersey, 1999.
 19. Werbos, P.J., **Beyond Regression: New Tools for Prediction and Analysis in the Behavioral Sciences**, PhD thesis, Harvard University, 1974.
 20. Rumelhart, D.E., Hinton, G.E., Williams, R.J., "Learning Internal Representation by Back-Propagating Errors", In: Rumelhart D.E., McClelland J.L., **The PDP Research Group, Parallel Distributed Processing: Explorations in the Microstructure of Cognition**, MIT Press, MA, 1986.
 21. Kartalopoulos, S.V., **Understanding Neural Network and Fuzzy Logic**, IEEE Press, New York, 1996.
 22. Demuth, H., Beale, M., **Neural Network Toolbox For Use With MATLAB User's Guide Version 4**, MA, 2000.
 23. Altaş, M., Özkan, H.F., Çelebi E., 2002 "Enerji İstatistikleri", **Türkiye 9. Enerji Kongresi**, 220, İstanbul, 2002.
 24. Devlet İstatistik Enstitüsü, **Elektrik, Gaz ve Su İstatistikleri**, 4, 19.
 25. Faraway, J., Chatfield, C., "Time Series Forecasting With Neural Networks: A Comparative Study Using The Airline Data", **Appl. Statist.**, Cilt 47, 231-250, 1998.