

# Diferansiyel Evrim Algoritması Destekli Yapay Sinir Ağı ile Orta Dönem Yük Tahmini

İbrahim EKE

Gazi Üniversitesi Mühendislik Fakültesi Elektrik Elektronik Mühendisliği Bölümü 06570 Maltepe, Ankara  
Telefon: +90 (312) 352-3314; Faks: +90 (312) 230-8434, ibrahimeke@gazi.edu.tr

**Özet—** Yük tahmini, güç üretim sürecinin önemli bir kısmı olup, yıllardır zaman serileri gibi geleneksel yaklaşımlarla elde edilmiştir. Fakat son zamanlarda yapay zekaya dayalı yeni yöntemler ortaya çıkmış olup bu yeni uygulamalar endüstride geleneksel tahminlerin yerini almaya başlamıştır. Bu çalışma diferansiyel evrim algoritması (DE) ile yapay sinir ağlarının (YSA) karma bir çalışmasını yük tahmini için DE-YSA olarak sunar. Çalışma yapay sinir ağları eğitiminde DE algoritmasının performansını test etmektedir. Çalışma çıktılarının birbir karşılaştırılmasından da anlaşılacağı üzere DE-YSA diğer metoda göre daha iyi bir performans göstermektedir.

**Anahtar Sözcükler —** Yük tahmini, diferansiyel evrim algoritması, yapay sinir ağlarının

MEDIUM-TERM LOAD FORECASTING BY ARTIFICIAL NEURAL NETWORK BASED DIFFERENTIAL EVOLUTION

**Abstract—** Load forecasting is an important part of the power generation process. For years, it has been achieved by traditional approaches stochastic like time series; but, new methods based on artificial intelligence emerged recently in literature and started to replace the old ones in the industry. This study presents an intelligent hybrid approach called DE-ANN by hybridization of Differential Evolution (DE) and Artificial Neural Network. In this work, performance of the Differential Evolution, a recently proposed algorithm, has been tested on training on Artificial Neural Networks. The performance of the algorithm has been compared to traditional Artificial Neural Networks Results show that DE algorithm outperforms the other method.

**Index Terms—** Load forecasting, differential evolution, artificial neural network

## I. GİRİŞ

Ülkelerin sanayileşmesinde, kalkınmasında ve gelişmişlik düzeylerinin artmasında elektrik enerjisinin etkisi tartışılmazdır. Kullanım kolaylığı, temizliği ve atık bırakmaması nedeniyle diğer enerji kaynaklarına göre elektrik enerjisi tüketiminin genel enerji tüketimi içindeki payı, sanayileşmiş ülkeler de dahil olmak üzere tüm dünyada hızla artmaktadır. Elektrik enerjisinin depo edilememe özelliği nedeniyle üretildiği anda tüketilmesi gerektiğinden elektrik

enerjisi üretiminde, iletiminde, dağıtımında ve tüketiminde verimlilik kavramları son derece önemlidir. Elektrik enerjisinin sağlıklı ve yüksek verimle kullanılabilmesi için, tüketilen elektrik enerjisi kadar elektrik enerjisi üretilmesi gerekmektedir. Üretim planlama çalışmasının temelini oluşturan yük tahmini de elektrik enerji sektörü için son derece önemli ve gerekli bir kavramdır. Yük tahmini, geçmişteki koşulların incelenerek gelecekteki durumun öngörülmesidir. Yük tahminlerini kısa, orta ve uzun dönemli olmak üzere üç değişik boyutta incelemek mümkündür [1]. Kısa vadeli tahmin, bakım programlarının oluşturulmasında ve satın alınacak yakıt ile enerji için gerekli olan bütçe tahsisinin belirlenmesinde kullanılmaktadır. Ayrıca kısa vadeli tahmin dağıtım sistemi tesis programlarının ayarlanmasında kullanılabilir. Orta vadeli tahmin, fiziksel tesislerin planlamasında son derece önemli olan zaman dilimini kapsamaktadır. Çünkü, üretim tesislerinin inşası için gerekli olan zaman, orta vadeli tahmin süresi ile örtüşmektedir. Uzun vadeli tahminler planlama stratejisi belirlenmesinde, yakıt gereksinimleri ve yakıt kaynaklarının tespitinde kullanılır. Kısa dönem yük tahmini 1 yıllık süreyi, orta dönem yük tahmini 5 yıllık süreyi ve uzun dönem yük tahmini 10 yıllık süreyi kapsar.

Son yıllarda Türkiye’de yük tahmini analizinde birçok çalışmalar yapılmıştır. Erkmen ve Özdoğan modifiye kohonen algoritması ile yapay sinir ağları kullanarak tahminde bulunmuşlardır [2]. Eşiyok ve arkadaşları yapay sinir ağlarını kullanarak İstanbul’un bazı bölgeleri için yük tahmin analizini gerçekleştirmişlerdir [3]. Topallı ve Erkmen tarafından yapılan diğer bir çalışmada Türkiye için 2001 yılı günlük yük tahmini yapılmıştır [4] YSA kullanılarak yapılan modelde veri olarak 2000 yılına ait yük verileri ve haftanın hangi günü olduğunu belirten takvim verileri kullanılmıştır. Hengirmen ve Kabak [5] Gaziantep yöresi için yük tahmin analizini en küçük kareler yöntemi ile gerçekleştirmişlerdir. Hengirmen [6] en küçük kareler, basit üstel ve hareketli ortalamalar metodlarını kullanarak Gaziantep bölgesinin enerji ihtiyacını tahmin etmiştir. Yalçınöz ve Eminoğlu tarafından Niğde ilinin günlük toplam yük ve tepe yüklerinin tahmin edildiği çalışmada yük ve sıcaklık verileri kullanılmıştır [7]. Yalçınöz ve arkadaşları beş farklı yöntemle Niğde bölgesine ait yük tahmin analizini gerçekleştirmişlerdir [8]. Topallı ve arkadaşları tarafından Türkiye’ye ait günlük yükün tahmin edildiği çalışmada YSA yöntemi kullanılmış, 2001 ve 2002 yıllarına ait yük ve sıcaklık verilerinden de faydalanılmıştır [8]. Yük verilerinin tüm Türkiye’ye ait olmasına rağmen, sadece İstanbul’a ait

sıcaklık verileri kullanılmıştır. Topallı ve arkadaşları [9] elektrik tüketiminin tahmin edilmesini yapay sinir ağları ile günlük veriler kullanarak gerçekleştirmişlerdir. Elde edilen sonuçlar kısa dönem planlarının yapılmasına imkan sağlamakta ve az bir hata değeri ile tahmin yapılmasına olanak vermektedir. Ceylan ve Demirören ise Gölbaşı bölgesine ait kısa dönem yük tahminini, 2002 ve 2003 yıllarına ait yük ve sıcaklık verilerini kullanarak yapmışlardır [10].

Bu çalışmada orta dönem yük tahmini problemine diferansiyel evrim algoritması (DE) destekli yapay sinir ağları (YSA) yöntemi ile çözüm getirmek amaçlanmıştır. Yapay sinir ağlarının geçmiş bilgi ve deneyimlerden yararlanması, eksik veya hatalı bilgilerle çalışıyor olması, karmaşık ilişkileri öğrenebilmesi özelliğiyle tahmin problemleri için iyi bir yöntem olarak görülmektedir. Bir yapay sinir ağının zeki davranışı, bağlantı hatları üzerindeki ağırlıkların değerleriyle ölçülür. Bu ağırlıklar, ağın sahip olduğu bilgiyi temsil ederek bir genelleme yaparlar. Ağın zeki bir davranış sergileyebilmesi için mevcut tüm ağırlıkların yapay sinir ağları tarafından öğrenilmesi ve istenen özellikleri genelleştirecek şekilde en uygun değerlere sahip olmasıdır. Ağırlıkların değiştirilerek en uygun ağırlıkların bulunması klasik olarak değil diferansiyel evrim algoritması ile gerçekleştirilmiştir. Ayrıca tahmin için birtakım teknik ve sosyal verilerden faydalanılarak 2010-2012 yılı tahmini gerçekleştirilmiştir.

## II. TAHMİN VE TAHMİN YÖNTEMLERİ


Tahmin, bilinmeyen bir parametre değerinin, bilinen parametreler kullanılarak, bu bilinen parametrelerin tanımladığı şartlar dahilinde kestirilmesi veya bir parametrenin bilinen değerlerinin kullanılarak gelecekteki durumunun kestirilmesidir. Tahmin yöntemleri genellikle kalitatif (nitelikli) ve kantitatif (nicelikli) olarak sınıflandırılmakta, matematiksel ve istatistiksel yöntemlere dayanmaktadır [11]. Pazar araştırması, uzman görüşleri, delphi tekniği nitelikli tahmin yöntemleri olup, zaman serisi analizi (basit yaklaşımlar, hareketli ortalamalar, üstel düzeltmeler tekniği, trend analizi, Box-Jenkins yöntemi) ve karma yöntemler (basit regresyon analizi, çoklu regresyon analizi, ekonometrik modeller, yapay zeka ve sezgisel algoritmalar) nicelikli tahmin yöntemleridir. Bu çalışmada kullanılan tahmin yöntemi ise diferansiyel evrim algoritması destekli yapay sinir ağlarıdır (DEGYSA).

## III. YAPAY SINİR AĞLARI

Yapay sinir ağları insan sinir hücresinin öğrenme ve sinyal transferi fonksiyonlarının modellenmesi ile ortaya çıkmıştır. Doğrusal olmayan veriler arasındaki ilişkileri öğrenebilme ve çıkarsama yapabilme özellikleri ile geleneksel yöntemlere göre daha çok alanda uygulanmakta olup daha başarılı sonuçlar elde edilmektedir.

Biyolojik sinir ağları beynimizde bulunan birçok sayıda sinir hücresinin bir koleksiyonudur. Bir sinir ağı milyonlarca sinir hücresinin bir araya gelmesi ile oluşmaktadır. Temel bir yapay sinir ağı hücresi biyolojik sinir hücresine göre çok daha basit bir yapıya sahiptir. Yapay sinir hücreleri mühendislik

biliminde işlem elemanları olarak da adlandırılmaktadır. Bir yapay sinir hücresi Şekil 1'den de görüleceği üzere girdiler, ağırlıklar, toplama fonksiyonu, aktivasyon fonksiyonu ve çıktı olmak üzere beş ana kısımdan oluşur [12].



Şekil 1. Yapay Sinir Ağı Modeli

Şekil 1'de  $X_{1-n}$  yapay sinir ağı için kullanılacak girişleri ifade etmekte olup  $W_{1-n}$  yapay sinir ağlarında katmanlar arasındaki ağırlıkları ifade etmektedir.  $\Sigma$  ve  $b$  ise giriş ve ağırlıkların toplama fonksiyonu tarafından yapay sinir ağları çözümünde etkin bir rolü olan eşik değeri ile işleme tabii tutulması ifade etmektedir. Ayrıca yapay sinir ağlarından çıkış elde edebilmek için kullanılacak olan aktivasyon fonksiyonu  $f$  ile ifade edilmiştir. Bir yapay sinir hücresine dış dünyadan gelen bilgiler girdiler olarak kabul edilir. Ağırlıklar ise bir yapay hücreye gelen bilginin önemini ve hücre üzerindeki etkisini gösterir. Bir hücreye gelen net girdi toplama fonksiyonu ile hesaplanır. Bunun için değişik fonksiyonlar kullanılır. Genelde her gelen girdi değeri kendi ağırlığı ile çarpılarak toplanır. Böylece ağa gelen net girdi bulunmuş olur. Net girdi aşağıdaki eşitlikteki gibi ifade edilir.

$$net = \sum_{i=1}^n G_i A_i \quad (1)$$

Burada  $G$  girdileri,  $A$  ise ağırlıkları,  $n$  ise bir hücreye gelen toplam girdi sayısını gösterir. Hücreye gelen net girdiyi işleyerek hücrenin bu girdiye karşılık üreteceği çıktıyı aktivasyon fonksiyonu belirler. Toplama fonksiyonunda olduğu gibi çıktıyı hesaplamak için değişik aktivasyon fonksiyonu formülleri kullanılır. Günümüzde en yaygın olarak sigmoid fonksiyonu kullanılır ve şöyle ifade edilir:

$$f(net) = \frac{1}{1 + e^{-net}} \quad (2)$$

Burada  $net$ , işlem elemanına gelen toplam fonksiyonunu kullanarak belirlenen girdi değerini göstermektedir.

Yapay sinir ağlarını bağlantı tiplerine göre üç sınıfta inceleyebiliriz. Bunlar

1- İleri beslemeli ağ: Her bir katmandaki hücreler sadece bir önceki katmanın hücrelerince beslenir.

2- Kaskat bağlantılı ağ: Hücreler sadece önceki katmanlardaki hücrelerce beslenir.

3- Geri beslemeli ağ: En az bir hücre, sonraki katmanlardaki hücrelerce de beslenir.

Yapay sinir ağlarında bazı ağlar ileri besleme şeklinde yapılandırılırken, bazı ağlar ise geri besleme yapısı içermektedir. İleri besleme sinir ağlarında, işlem elemanları arasındaki bağlantılar bir döngü oluşturmazlar ve bu ağlar genellikle hızlı bir şekilde karşılık üretirler. Geri beslemeli ağlarda ise bağlantılar döngü içerirler ve hatta her seferinde yeni veri kullanabilmektedirler.

Yapay sinir ağlarında sinir hücrelerinin bağlantılarının yani ağırlık değerlerinin belirlenmesi işlemine ağırlık eğitilmesi denir. Yapay sinir ağları öğrenme yöntemleri aşağıdaki gibi ifade edilir.

Hebb öğrenme kuralı: İlk ve en eski bilinen öğrenme kuralı Hebb öğrenme kuralıdır. Eğer birbirine bağlı iki nöron, aynı anda aynı işarete sahipse, bu nöronlar arasındaki ağırlık değeri artırılır [13].

Hopfield kuralı: Hopfield ağı tek katmanlı ve geri dönüşümlü bir ağıdır. Proses elemanlarının tamamı hem girdi hem de çıktı elemanlarıdır. Ağırlık bağlantı değerleri bir enerji fonksiyonu olarak saklanmaktadır.

Delta kuralı: En çok kullanılan kurallardan biri olan Delta kuralı Hebb kuralının geliştirilmiş halidir. Beklenen çıktı ile gerçekleşen çıktı arasındaki farkı (delta) azaltmak için yani hedefe yaklaşmak için ağırlıkların sürekli değiştirilmesi varsayımına dayanmaktadır [14].

Kohonen kuralı: Bu kural, biyolojik sistemlerdeki öğrenmeden esinlenerek Kohonen tarafından geliştirilmiştir [15]. Bu kuralda nöronlar öğrenmek için yarışır. Kazanan nöronun ağırlıkları güncellenir. Bu kural "kazanan tamamını alır" olarak da bilinir.

#### IV. DİFERANSİYEL EVRİM ALGORİTMASI

Diferansiyel evrim algoritması (Differential Evolution, DE)) ilk olarak 1995 yılında K. Price tarafından ortaya konmuştur [16]. Diferansiyel evrim algoritması çaprazlama, mutasyon ve seçim gibi genetik algoritmalarda bulunan benzer operatörleri kullanan ve son zamanlarda popüler olan popülasyon tabanlı bir algoritmadır. DE'nin önemli parametreleri; popülasyon büyüklüğü ( $N_p$ ), çaprazlama sabiti ( $Cr$ ) ve ölçekleme faktörü ( $F$ ) olarak sayılabilir.

Bir DE algoritmasının temel adımları aşağıdaki gibidir;

- Başlangıç popülasyonunun oluşturulması
- Değerlendirme
- Aşağıdaki adımları durma kriteri sağlanıncaya kadar tekrarla
- Mutasyon
- Çaprazlama
- Seçim

Mutasyon; popülasyon içerisinde rasgele seçilen bir popülasyon bireyine, yine rasgele seçilen iki vektörün

ölçeklendirilmiş farkını ekleyen bir süreçtir.  $S$  popülasyonundan  $x_i$  için

$x_{P(1)}, x_{P(2)}, x_{P(3)} \mid x_{P(1)} \neq x_{P(2)} \neq x_{P(3)} \neq x_i$   
olacak şekilde rasgele üç çözüm seç ve Eşitlik 3 ile mutasyona uğramış yeni çözüm üret.

$$x_i = x_i + K(x_{P(3)} - x_i) + F(x_{P(1)} - x_{P(2)}) \quad (3)$$

$F$  ve  $K$  değerleri (0,1) arasında olan ölçekleme faktörleridir.

Çaprazlama;  $Cr$  katsayısı dikkate alınarak mutasyon sonucunda oluşan yeni vektörden hangilerinin alınacağı belirlenmektedir. 0 ile 1 arasında üretilen rastgele sayı  $Cr$ 'den küçükse  $n_{j,i,G+1}$ 'den aksi takdirde mevcut vektörden seçilir. Amaç belirlenen oranda bireyin yeni fark vektörden alınmasıdır. Çaprazlama işleminin matematiksel ifadesi Eşitlik 4'de gösterilmektedir;

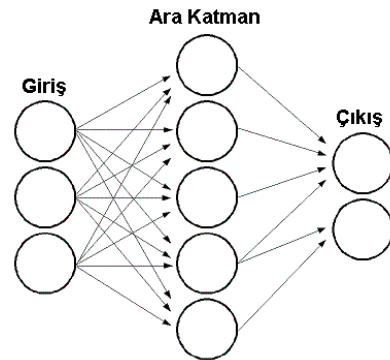
$$\forall j \leq D : x_{j,u,G+1} = \begin{cases} x_{j,n,G+1} & \text{eger } \text{rand}[0,1] \leq CR \vee j = j_{rand} \\ x_{j,i,G} & \text{aksi durumda} \end{cases} \quad (4)$$

Burada değişken sayısı  $D$ , vektör parametresi  $i$ , birey parametresi  $j$  ve mutasyon ve çaprazlamaya tabi tutulmuş ara vektör  $n_{j,i,G+1}$  olarak ifade edilir.

Seçim; deneme vektörü ve onun ebeveyninin performansları karşılaştırılarak iyi olan seçilir. Bu yöntem genellikle, açgözlü (greedy) seçim olarak adlandırılır. Kalite değerlerine bağlı olmaksızın bütün çözümlerin ebeveyn olarak seçilme şansları eşittir. Deneme çözümü ve onun ebeveyninden daha iyi olanı seçilir. Bu sayede yakınsama hızı açısından genetik algoritmaya göre önemli bir avantaj sağlanmış olur.

#### V. SIMULASYON ÇALIŞMALARI

Bu çalışmada Türkiye'nin orta dönem yük tahminini yapabilmek için yapay sinir ağları (YSA) ve diferansiyel evrim algoritması destekli yapay sinir ağları yöntemi kullanılmıştır. Ağ yapısı olarak geri yayımlı yapay sinir ağı tercih edilmiş ve veriler normalize edilerek ağa verilmiştir. Bu ağda 3 giriş, 1 ara katman ve 2 çıkış kullanılmış olup model Şekil 2'de gösterilmiştir.



Şekil 2. Tahmin yönteminde kullanılan YSA modeli

Ara katmanda 10 adet yapay nöron kullanılmıştır. Yük tahmini yapabilmek için 1981-2009 yılları arası bazı önemli veriler YSA için giriş ve çıkış olarak kullanılmıştır. YSA'da giriş olarak gayri safi yurtiçi hasıla (GSYİH), gayri safi milli hasıla (GSMH) ve nüfus değerleri kullanılmıştır. Bu değerler; Türkiye nüfusu (Milyon kişi), kişi başına düşen GSYİH(\$), enerji (GWh) ve puant yük (MW) değerleri Tablo 1'de verilmiştir.

Tablo 1. Yapay sinir ağı giriş ve çıkış değerleri

Yıllar	Nüfus*	GSYİH**	GSMH	Enerji***	Puant Yük****
1980	44,7	1518	70	24616,6	3947,4
1981	45,9	1546	73	26288,9	4085,8
1982	47,1	1360	66	28324,9	4512,6
1983	48,2	1261	62	29567,6	4730,7
1984	49,4	1195	61	33266,5	5456,8
1985	50,6	1320	68	36361,3	5758,4
1986	51,8	1459	76	40471,4	6434,1
1987	52,9	1629	88	44925	7466,5
1988	54,1	1685	91	48430	7679,4
1989	55,3	1933	109	52601,7	8556,3
1990	56,4	2655	152	56811,7	9180,4
1991	57,3	2603	152	60499,3	9964,9
1992	58,2	2682	161	67216,8	11113,3
1993	59,2	2981	182	73431,7	11921,4
1994	60,1	2173	131	77783	12759,7
1995	60,2	2727	172	85551,5	14164,6
1996	60,7	2801	185	94788,7	15230,7
1997	61,6	2959	194	105517,1	16926,1
1998	62,5	2997	206	114022,7	17799,3
1999	63,4	2807	188	118484,9	18938
2000	64,3	2963	201	128275,6	19389,9
2001	65,1	2696	145	126871,3	19612
2002	66	2865	183	132552,6	21005,6
2003	66,9	2984	238	141150,9	21728,9
2004	67,7	3231	302	150017,5	23485,3
2005	68,6	3425	363	160794	25174,2
2006	69,4	3589	400	174637,3	27594,4
2007	70,3	5396	659	190000,21	29248,5
2008	71,1	10436	950	198085,2	30516,8
2009	71,89	8456	608	198500	30600

YSA çıkışı için enerji (GWh) ve puant yük (MW) değerleri kullanılmıştır. Birinci aşamada geleneksel YSA yapısı kullanılarak eğitim tamamlanmış ve test verileri ile YSA yapısının öğrenmeyi tamamladığı anlaşılmıştır. İkinci aşamada bu çalışma için önerilen DE destekli YSA için ağıdaki öğrenmeyi sağlayan ağırlıklar optimize edilmiştir. Her iki yöntem için eğitim ve test hataları Tablo 2'de verilmiştir.

Tablo 2. Eğitim ve test hataları

	Eğitim Hatası		Test Hatası	
	Çıkış 1	Çıkış 2	Çıkış 1	Çıkış 2
YSA	%0.08	%0.9	%0.9	%0.8
DE-YSA	%0.1	%0.8	%0.2	%1.6

TEİAŞ tarafından 2010-2012 yılları arası en düşük ve en yüksek talep tahminleri Tablo 3 ve Tablo 4'de verilmiştir. Aynı tabloda YSA ve önerilen DE-YSA tahminleri de karşılaştırılmıştır. TEİAŞ tahminleri Türkiye elektrik sistemi için geçerli olup, brüt taleptir. Bu talebe iletim ve dağıtım hatlarındaki kayıplar, ile santrallerin iç ihtiyaçları da dahildir. Ayrıca dağıtım sistemine bağlı ve yük tevzi merkezinden talimat almayan üretim tesislerinin de üretimleri TEİAŞ talep tahmin çalışmaları içerisindedir.

Tablo 3. Puant Talep Tahmini

	TEİAŞ <sup>Düşük</sup>	YSA	DE-YSA	TEİAŞ <sup>Yüksek</sup>
2010	31246	31511	31433	31246
2011	32964	33401	33318	33276
2012	35173	35774	35685	35772

Tablo 4. Enerji Talep Tahmini

	TEİAŞ <sup>Düşük</sup>	YSA	DE-YSA	TEİAŞ <sup>Yüksek</sup>
2010	202730	204453	203946	202730
2011	213780	216720	216182	215907
2012	228210	232111	231536	232101

## VI. TARTIŞMA/SONUÇ

Bu çalışmada, Türkiye için orta dönem yük tahmini uygulaması, yapay sinir ağları (YSA) ve diferansiyel evrim algoritması destekli yapay sinir ağları (DE-YSA) metoduyla gerçekleştirilmiştir. Birinci modelde YSA'nda öğrenme geleneksel yöntem olan geri yayılım algoritması ile gerçekleşmiştir. İkinci model, DE-YSA'da ise öğrenmeyi sağlayan ağırlıklar DE ile optimize edilerek en uygun ağırlık değerleri hesaplanmıştır. Talep tahminini etkileyen faktörler olarak nüfus, gayri safi milli hasıla, petrol fiyatları gibi ekonomik ve sosyal göstergeleri temel alındığı değerlerden üç tanesi giriş olarak seçilmiştir. Son olarak, seçilen örnek veriler kullanılarak sonuçlar, hem DE destekli Yapay Sinir Ağları hem de YSA da test verileri ile karşılaştırılmıştır. Test sonuçlarına göre DE destekli YSA modeli Türkiye orta dönem yük tahmini için klasik YSA modelinden daha başarılı olmuştur. Tablo 2'den görüldüğü üzere, DE-YSA'nın hem eğitim hem de test hata sonuçları YSA ile karşılaştırıldığında daha düşük olduğu görülmüştür. Önerilen DE destekli YSA tahmin yönteminin etkinliğini görmek amacıyla, TEİAŞ'ın talep tahmini ile klasik YSA tahmini Tablo 3 ve Tablo 4'de karşılaştırılmıştır. TEİAŞ tarafından yapılan en küçük ve en düşük talep tahminlerine göre önerilen DE-YSA yapısının geleneksel YSA yapısından daha etkin olduğu görülmüştür. Sonuç olarak; nüfus artışı, kişi başına düşen milli gelir ve petrol fiyatları gibi doğrusal olmayan sosyal ve ekonomik değişkenleri kullanarak matematiksel bir model oluşturmak ve buna bağlı olarak enerji piyasasını oluşturan değişkenler arasında bağlantı kurup yük tahmini yapmak oldukça zordur. Bu çalışmada kullanıldığı gibi birbirinden bağımsız, doğrusal olmayan veriler ile yük tahmininde yapay sinir ağlarından faydalanmak büyük kolaylıklar sağlamaktadır. Önerilen yöntem de yapay sinir ağlarının eğitiminin temelini oluşturan ağırlıklar klasik YSA içinde değil de yapay zeka algoritmalarından DE ile optimize edilmiştir. Böylelikle daha iyi bir eğitim ile YSA daha doğru sonuçlar vermiştir.

## VII. KAYNAKLAR

- [1] H.M. Al-Hamadi and S.A. Soliman, "Long-term/mid-term electric load forecasting based on short-term correlation and annual growth", *Electric Power Systems Research*, Volume 74, Issue 3, Pages 353-361, 2005.
- [2] I. Erkmen. ve A. Özdoğan, "Short term load forecasting using genetically optimized neural network cascaded with a modified Kohonen clustering process", *International Symposium of Intelligent Control, Proceedings of the 1997 IEEE International Symposium*, Istanbul, Turkey, 107-112, 1997.
- [3] E. Eşiyok, A. T.Hocaoğlu ve M. Dumanlı, "Güç Sistemlerinde Yapay Sinir Ağları ile Yük Tahmin Analizi", *Elektrik Mühendisliği 6. Ulusal Kongresi*, pp. 69-72, 1995.
- [4] A. K. Topalli ve İ. Erkmen, "A hybrid learning for neural networks applied to short term load forecasting", *Neurocomputing*. Volume 51, Page 495-500, 2003.
- [5] Hengirmen M.O., Kabak S., 'Gaziantep ve Yöresinde 5 Yıllık Elektrik Enerjisi İhtiyaç Tahminleri', *Elektrik Elektronik Bilgisayar Müh. 8.Ulusal Kongresi*, pp.333-335, 1999.
- [6] Hengirmen M.O., 'Comparison of Three Forecast Methods for Power Demand in Gaziantep', *Eleco'99 International Conference on Electrical and Electronics Eng.*, Bursa, pp 185-188, 1-5-December,1999.
- [7] Yalçınöz T., Herdem S., Eminoğlu U., 2002, "Yapay Sinir Ağları ile Niğde Bölgesinin Elektrik Yük Tahmini", *Elektrik - Elektronik - Bilgisayar Mühendisliği Sempozyumu (ELECO 2002)*, 25-29, Bursa, 18-22 Aralık.
- [8] Yalçınöz T., Karadeniz Y. and Yücel İ., 'Niğde bölgesi için elektrik yük tahmini', *Eleco'2000 Elektrik - Elektronik - Bilgisayar Mühendisliği Sempozyumu*, pp. 43-47 (Elektrik), Bursa, 8-12 Kasım 2000.
- [9] Topalli A. K, Erkmen I., Topalli I., 2006, "Intelligent short-term load forecasting in Turkey", *Electrical Power and Energy Systems* 28, 437-447.
- [10] Ceylan G. ve Demirören A., 2007, "Yapay Sinir Ağları ile Gölbaşı Bölgesinin Kısa DönemYük Tahmini", *Elektrik, Elektronik ve Bilgisayar Mühendisliği Sempozyumu ve Fuarı (ELECO 2004)*, 8-12 Aralık, Bursa, 103-107.
- [11] A. Özdemir ve A. Özdemir, "Talep Tahminlemede Kullanılan Yöntemlerin Karşılaştırılması: Seramik Ürün Grubu Firma Uygulaması", *Ege Akademik Bakış Dergisi*, cilt 6, sayı 2 sayfa 105-114, 2006.
- [12] Haykin, S., "Neural Network A Comprehensive Foundation 2<sup>nd</sup> ed.", *Prentice-Hall*, New Jersey, 1-2, 14-15, 41-43, 161-162 ( 1999).
- [13] Fausett, L., "Fundamentals of Neural Networks Architectures, Algorithms and Applications", *Prentice-Hall*, New Jersey, 48-49 (1994).
- [14] S. J. Hanson, "A stochastic version of the delta rule", *Physica D: Nonlinear Phenomena* Volume 42, Issues 1-3, June 1990, Pages 265-272.
- [15] T.M. Heskes, B. Kappen, "Error potentials for self-organization", *Neural Networks*, 1993., *IEEE International Conference on*, 1219 - 1223 vol.3, 2002.
- [16] R. Storn and K. Price, Differential evolution-a simple and efficient heuristic for global optimization over continuous space, *Journal of Global Optimization*, 11, (1997), pp.341-359.