

İSTANBUL TEKNİK ÜNİVERSİTESİ ★ FEN BİLİMLERİ ENSTİTÜSÜ

**HİDROELEKTRİK ENERJİ ÜRETİMİNİN HİBRİD
BİR MODEL İLE TAHMİNİ**

**YÜKSEK LİSANS TEZİ
Didem Çınar**

Anabilim Dalı : ENDÜSTRİ MÜHENDİSLİĞİ

Programı : ENDÜSTRİ MÜHENDİSLİĞİ

HAZİRAN 2007

**HİDROELEKTRİK ENERJİ ÜRETİMİNİN HİBRİD BİR
MODEL İLE TAHMİNİ**

YÜKSEK LİSANS TEZİ
Didem Çınar
507051110

Tezin Enstitüye Verildiği Tarih : 7 Mayıs 2007
Tezin Savunulduğu Tarih : 13 Haziran 2007

Tez Danışmanları : Prof.Dr. M. Nahit Serarslan
Yard.Doç.Dr. Gülgün Kayakutlu
Diğer Jüri Üyeleri Yard.Doç.Dr. Cafer Erhan Bozdağ
Yard.Doç.Dr. Şule Önsel (D.Ü.)
Doç.Dr. Şebnem Burnaz

HAZİRAN 2007

ÖNSÖZ

Çalışmanın başında konuya karar vermek iki ayımı aldı. Enerji kaynaklarının yeterli düzeyde kullanılmaması Türkiye'nin gelişmesinin önündeki engellerden birisiyken ve küresel ısınma insanların en büyük korkusu olmuşken enerji konusunda çalışma yapmak benim için yeni ve öğretici bir konu olacaktı. Yapay sinir ağları ve genetik algoritmaların da bir sene öncesine kadar benim için yeni konular olduğunu düşününce, şu an bu çalışmanın bana bilmediğim çok şey kattığını görüyorum.

Öncelikle çalışmam boyunca bilgi ve deneyimlerinden yararlandığım danışman hocam Prof. Dr. M. Nahit Serarslan'a; enerji konusunda çalışmam için beni yüreklendiren, en bunaldığım anlarda fikirleriyle yolumu açan ve çalışmamın her kelimesinde emeği olan eş danışmanım Yard. Doç. Dr. Gülgün Kayakutlu'ya (Gülgün Hocam'a) sonsuz teşekkür ederim.

MATLAB'taki bütün soru ve sorunlarıma yılmadan yardımcı olan Murat Engin Ünal'a, tezimin formatında yardımcı olan Nüfer Yasin Ateş'e, çay ve moral destekleri için Fatma İnce ve Saliha Algül'e ve tabi ki engin tez kontrol tecrübesi ve dostluğuyla bana her zaman destek olan İhsan Kaya'ya çok teşekkür ederim.

Sevdiğim işi yapmamda beni yüreklendirdikleri ve her zaman destek oldukları için en son ve en büyük teşekkür ise aileme. Bu çalışma "bizim" emeğimizin ürünüdür ve umarım gelecek çalışmalara ışık tutan bir çalışma olur.

Mayıs, 2007

Didem Çınar

İÇİNDEKİLER

KISALTMALAR	v
TABLO LİSTESİ	vi
ŞEKİL LİSTESİ	vii
ÖZET	viii
SUMMARY	ix
1. GİRİŞ	1
2. TÜRKİYE’NİN ENERJİ BAKIMINDAN DURUMU	3
3. TÜRKİYE’DE YAPILAN ENERJİ TAHMİN ÇALIŞMALARI	9
4. ÇALIŞMANIN AMACI	17
5. YAPAY SİNİR AĞLARI	19
5.1. Yapay Sinir Ağlarına Giriş	19
5.2. Tek ve Çok Katmanlı Algılayıcılar	20
5.3. Yapay Sinir Ağlarında Öğrenme	28
5.3.1. Gözetimli Öğrenme	29
5.3.2. Gözetimsiz Öğrenme	30
5.3.3. Karma Öğrenme	30
5.4. Geri Yayılmalı Algoritma	31
5.5. Yapay Sinir Ağının Yapısının ve Parametrelerinin Belirlenmesi	33
5.6. Yapay Sinir Ağlarının Tahmin Modellerinde Kullanımı	35
6. GENETİK ALGORİTMALAR	37
6.1. Genetik Algoritmalarla İlgili Temel Kavramlar	37
6.2. Genetik Algoritmaların Temel Çalışma Prensipleri	38
6.3. Genetik Algoritmaların Geleneksel Yaklaşımlardan Farkı	40
6.4. Genetik Algoritmaların Temel Bileşenleri	41
6.4.1. Genetik Kodlama	41
6.4.2. Uygunluk Fonksiyonu	42
6.4.3. Başlangıç Popülasyonu Oluşturma	42
6.4.4. Genetik Operatörler	43
6.5. Genetik Algoritmaların Kullanım Alanları	44
7. ÖNERİLEN MODEL	46
7.1. Genetik Algoritmalar ile Yapay Sinir Ağlarının Birarada Kullanılması	46
7.1.1. Optimum Ağırlıkların Belirlenmesi	49
7.1.2. Optimum parametrelerin ve sinir ağı yapısının belirlenmesi	50
7.1.3. Girdilerin belirlenmesi	52
7.2. Modelin Algoritması	53
7.3. Modelin Diğer Tahmin Yöntemlerinden Farkı	59
8. MODELİN UYGULANMASI	61
8.1. Örnek Seçimi	61
8.2. Hidroelektrik Enerji Üretim Tahmini	61
8.2.1. Girdilerin belirlenmesi	61

8.2.2.	Veri özellikleri	62
8.2.3.	Uygun YSA Yapısını Belirleme	63
8.2.4.	Çıktı Hesapları	64
8.2.5.	Performans Analizi	66
8.2.6.	Tahmin	67
8.3.	Enerji İthalatı	68
8.3.1.	Girdilerin belirlenmesi	68
8.3.2.	Veri özellikleri	69
8.3.3.	Uygun YSA Yapısını Belirleme	71
8.3.4.	Çıktı Hesapları	72
8.3.5.	Tahmin	73
8.4.	Uygulama Sonuçları	74
9.	SONUÇ VE ÖNERİLER	76
	KAYNAKLAR	78
	EKLER	83
	ÖZGEÇMİŞ	98

KISALTMALAR

AR	: Autoregressive
ARMA	: Auto Regressive Moving Average
ARIMA	: Auto Regressive Integrated Moving Average
DSİ	: Devlet Su İşleri
ETBK	: Enerji ve Tabii Kaynaklar Bakanlığı
GA	: Genetik Algoritmalar
GSYH	: Gayrisafi Yurtiçi Hasıla
GYA	: Geri Yayılmalı Algoritma
MA	: Hareketeli Ortalama (Moving Average)
MSE	: Hata Karelerinin Ortalaması (Mean Square Error)
OECD	: Organisation for Economic Co-operation and Development
RE	: Göreli Hata (Relative Error)
RMSE	: Hata Karelerinin Ortalamasının Karekökü (Root Mean Square Error)
TEİAŞ	: Türkiye Elektrik İletim A.Ş.
TEP	: Ton Eşdeğer Petrol
YSA	: Yapay Sinir Ağları

TABLO LİSTESİ

	<u>Sayfa No</u>
Tablo 2.1 2005 Yılında Türkiye ve Dünya’da Enerji Tüketimi ve Gayrisafi Milli Hasıla	5
Tablo 3.1 2000-2007 yılları arasında Türkiye’de enerji tahmini konusunda yapılan çalışmalar	11
Tablo 5.1 AND Fonksiyonunun girdi ve çıktıları	22
Tablo 5.2 XOR Fonksiyonunun girdi ve çıktıları.....	22
Tablo 7.1 GA ile YSA’nın birarada kullanıldığı çalışmalar.....	47
Tablo 7.2 GYA’nın parametreleri ve alabilecekleri değer aralıkları.....	56
Tablo 8.1 Hidroelektrik tahmininde kullanılan modelin girdi sinir hücreleri ile gizli sinir hücreleri arasındaki başlangıç ağırlıkları	64
Tablo 8.2 Hidroelektrik tahmininde kullanılan modelin gizli sinir hücreleri ile çıktı sinir hücreleri arasındaki başlangıç ağırlıkları	64
Tablo 8.3 Girdi sinir hücreleri ile gizli sinir hücreleri arasındaki nihai ağırlıklar	64
Tablo 8.4 Gizli sinir hücreleri ile çıktı sinir hücreleri arasındaki nihai ağırlıklar .	64
Tablo 8.5 Girdilerin önem dereceleri	66
Tablo 8.6 Alternatif modellerin hata değerleri	71
Tablo 8.7 İthalat tahmininde kullanılan modelin girdi sinir hücreleri ile gizli sinir hücreleri arasındaki başlangıç ağırlıkları	72
Tablo 8.8 İthalat tahmininde kullanılan modelin gizli sinir hücreleri ile çıktı sinir hücreleri arasındaki başlangıç ağırlıkları	72
Tablo 8.9 Girdi sinir hücreleri ile gizli sinir hücreleri arasındaki nihai ağırlıklar	72
Tablo 8.10 Gizli sinir hücreleri ile çıktı sinir hücreleri arasındaki nihai ağırlıklar .	73
Tablo 8.11 Girdilerin önem dereceleri	73

ŞEKİL LİSTESİ

	<u>Sayfa No</u>
Şekil 2.1 : 2006 yılı elektrik üretiminin birincil enerji kaynaklarına göre dağılımı .	8
Şekil 3.1 : Enerjinin planlanması ve tahmin edilmesi	10
Şekil 5.1 : Yapay Sinir Ağlarının tarihsel gelişimi	19
Şekil 5.2 : Örnek bir algılayıcı	20
Şekil 5.3 : K paralel algılayıcı	21
Şekil 5.4 : AND Fonksiyonu gösteren örnek bir algılayıcı ve grafiksel gösterimi	22
Şekil 5.5 : XOR Fonksiyonunun grafiksel gösterimi	22
Şekil 5.6 : Örnek bir çok katmanlı algılayıcı	24
Şekil 5.7 : Tek çıktısı olan bir çok katmanlı algılayıcının yapısı	24
Şekil 5.8 : Eşik fonksiyonunun grafiksel gösterimi	25
Şekil 5.9 : Parçalı doğrusal fonksiyonun grafiksel gösterimi	26
Şekil 5.10 : Sigmoid fonksiyonun grafiksel gösterimi	27
Şekil 5.11 : Hiperbolik tanjant fonksiyonunun grafiksel gösterimi	27
Şekil 5.12 : XOR Probleminin çözümünü veren sinir ağı yapısı	28
Şekil 6.1 : Gen, kromozom ve popülasyon örnek gösterimi	37
Şekil 6.2 : Genetik Algoritmanın genel işleyişi	39
Şekil 6.3 : Basit çaprazlama operatörü	43
Şekil 7.1 : Önerilen modelin algoritmasını gösteren akış diyagramı	54
Şekil 7.2 : Örnek bir sinir ağı ve kromozom yapısı	56
Şekil 7.3 : Önerilen model için bir çaprazlama örneği	58
Şekil 8.1 : Hidroelektrik üretimi tahmininde kullanılacak olan YSA modeli	62
Şekil 8.2 : 1970-2005 yılları arası Türkiye’de hidroelektrik üretimi	63
Şekil 8.3 : 2005-2010 yılları arası hidroelektrik üretim tahmini	68
Şekil 8.4 : Enerji ithalatı tahmininde kullanılacak olan yapay sinir ağı modeli	69
Şekil 8.5 : 1970-2005 yılları arası Türkiye’de toplam birincil enerji tüketimi	70
Şekil 8.6 : 1970-2005 yılları arası Türkiye’de ithal edilen birincil enerji	70
Şekil 8.7 : 1970-2004 yıllarında Türkiye’de ithalatın enerji tüketimindeki payı	71
Şekil 8.8 : 2005-2010 yılları arası enerji ithalatı tahmini	73
Şekil 8.9 : Hidroelektrik üretimi ve enerji ithalatı karşılaştırmalı grafiği	75

HİDROELEKTRİK ENERJİ ÜRETİMİNİN HİBRİD BİR MODEL İLE TAHMİNİ

ÖZET

Enerji bir ülkenin kalkınma düzeyini gösteren temel göstergelerden biridir. Bu durum ülkeler için enerji kaynaklarını oldukça önemli kılar. Sürdürülebilir kalkınmanın sürdürülebilir enerji kaynaklarına bağlı olduğu düşünüldüğünde, fosil yakıtların tükenecek olması tükenmediği varsayılan yenilenebilir enerjinin önemini artırmaktadır.

Türkiye çok çeşitli enerji kaynaklarına sahip olmasına rağmen enerji ihtiyacının büyük bölümünü yabancı kaynaklardan sağlamaktadır ve ithal edilen kaynaklar fosil kaynaklardır. Hem ekonomik hem de çevresel faktörlerden dolayı dünyada olduğu gibi Türkiye’de de yenilenebilir enerji kaynaklarının kullanımının artırılması gerekmektedir. En büyük yenilenebilir enerji kaynağı olan hidroelektriğin üretiminin planlanması Türkiye’nin geleceğini planlamasında önemli rol oynayacaktır.

Enerji planlama, geleceğe yönelik enerji politikaları, stratejileri ve projeleri geliştirmek için önemlidir. Bu çalışmada Türkiye’nin en büyük yenilenebilir enerji potansiyeli olan hidroelektrik enerjinin üretim tahmini yapılmış ve ithalat tahminleri ile karşılaştırılarak 2010 yılına kadar Türkiye’nin enerji durumuna dair çıkarımlar yapılmıştır. Enerji tahmin çalışmaları incelendiğinde son yıllarda tahmin modeli olarak yapay sinir ağları gibi öğrenen sistemlerin kullanımının yaygınlaştığı görülmüştür. Yapay sinir ağlarının karmaşık problemleri rahatlıkla çözmesi ve her hangi bir varsayıma gerek duymaması tahmin modeli olarak kullanılmasının nedenleri arasındadır.

Bu çalışma kapsamında da tahmin modeli olarak geri yayılma algoritması ile eğitilen yapay sinir ağları kullanılmıştır. Geri yayılma algoritması yerel optimuma takılabilen bir gradyan inişi (gradient descent) yöntemidir. Geri yayılma algoritmasının yerel optimuma takılma riskini azaltmak amacıyla bir stokastik arama tekniği olan genetik algoritmalar kullanılmıştır. Önerilen bu hibrid modelde genetik algoritmaların kullanılma amacı, yapay sinir ağının parametrelerinin iyileştirilmesidir. Bir başka deyişle genetik algoritma ile parametreleri bulunan YSA modeli, Türkiye’nin hidroelektrik üretimi ve enerji ithalat tahmininde kullanılmıştır.

FORECASTING PRODUCTION OF RENEWABLE ENERGY USING A HYBRID MODEL

ABSTRACT

Energy is considered to be a key indicator for economic development; hence, energy resources are extremely important for the national economies. The sustainable development demands a sustainable supply of energy yet, fossil energy resources are finite and as a consequence the renewable energy needs a prioritised focus.

Although Turkey has various energy resources, the major portion of energy consumption is provided by importation, a big share of which is given to the fossil fuels. Whereas, both economic and environmental factors enforce the increasing use renewable energy in Turkey, as in the whole globe. Production planning of hydroelectric energy, the biggest renewable energy resource of Turkey, will be the key player for the future plans of the country.

Energy planning is necessary for better energy policies, strategies and projections. In this study, production of hydroelectric energy and energy importation were forecasted and compared with estimation of energy imports for making inferences on national energy status until 2010.

Intelligent systems, e.g. artificial neural networks (ANN), are used widely in energy forecasting in recent years. ANN has become a methodology of focus since it does not need any assumptions and is successful in solving complex problems.

In this study a neural network which is trained by back-propagation algorithm was used as forecasting model. Back-propagation is a gradient descent technique which tends to trap at local optimum. In order to reduce the probability this weakness, a stochastic search technique, genetic algorithms are included. This study proposes a hybrid model by optimizing the parameters of neural network through the genetic algorithms. The model is applied in forecasting the hydroelectric generation and primary energy imports of Turkey.

1. GİRİŞ

Enerji tüketimi ve enerji kaynaklarının çeşitliliği bir ülkenin gelişimini belirleyen en önemli etkenlerdir. Elektrik endüstriyel üretimde önemli bir girdidir. Bu bağlamda Türkiye'nin enerji üretiminde dışa bağımlı olması ülke gelişimi için büyük bir dezavantajdır. Türkiye coğrafik açıdan çok çeşitli enerji kaynaklarına ve zengin bir enerji potansiyeline sahiptir. Türkiye'nin en büyük enerji kaynaklarından biri olan hidroelektrik enerji yenilenebilir bir enerji türü olduğundan günümüzün en büyük çevresel problemi olan küresel ısınma için bir çözüm yoludur.

Elektrik üretiminin büyük bir bölümünü yabancı kaynaklarla sağlayan Türkiye, kaynaklarının çeşitliliği ve yerli kaynaklarla elektrik üretimi konusunda enerji politikaları uygulayarak yenilenebilir enerjinin üretim ve tüketimini artırmalıdır. Bu çalışmanın amacı hidroelektrik enerji üretiminin gelecekteki üretim miktarını ve elektrik üretiminde kullanılan ithal kaynakları tahmin ederek ülkenin enerji politikası için hidroelektrik enerji üretimini temel alan bir öneri geliştirmektir. Elde edilen gelişmelerin gelecek yatırımlar için bir karar destek sistemi oluşturması hedefi ile yeni bir tahmin modeli geliştirilmiştir.

Önerilen model, tahmin modellerinde oldukça başarılı sonuçlar veren yapay sinir ağları yöntemini iyileştirmeyi amaçlamaktadır. Modelde yapay sinir ağları ve genetik algoritma yaklaşımları kullanılmıştır. Genetik algoritma yapay sinir ağının parametrelerinin belirlenmesinde kullanılmıştır. Bu sayede yapay sinir ağlarının yerel optimuma takılma tehlikesi ile başedilmeye çalışılmıştır.

Çalışmanın bundan sonraki bölümünde Türkiye'nin enerji durumu ve yaşanan problemlere değinilmiştir. Enerji ve elektrik üretiminde Türkiye'nin dünyadaki yeri ve hidroelektrik üretiminin Türkiye için önemi açıklanmıştır. Üçüncü bölümde Türkiye'de 2000-2007 yıllarında enerji tahmini konusunda yapılan çalışmalar anlatılmıştır. Çalışmalarda kullanılan yöntemler ve inceledikleri enerji türleri incelenmiştir. Dördüncü bölümde ise enerji üzerine yapılan tahmin çalışmalarında görülen eksikler ve gelişmelerden hareketle çalışmanın amacı anlatılmıştır.

Beşinci ve altıncı bölümler çalışmada kullanılan iki yöntem hakkında genel bilgiler içermektedir. Beşinci bölümde yapay sinir ağlarının genel yapısı, kullanım amacı, karşılaştığı güçlükler ve tahmin modellerindeki kullanımı hakkında genel bilgiler verilmiştir. Altıncı bölümde de genetik algoritmaların genel yapısı ve kullanım amaçları açıklanmıştır.

Yedinci bölümde genetik algoritmaların yapay sinir ağlarında kullanıldığı çalışmalar incelenmiş ve çalışmada önerilen model anlatılmıştır. Yapay sinir ağları ve genetik algoritmalarda belirlenmesi gereken ve uygulamada kullanılacak olan parametreler bu bölümde açıklanmıştır. Sekizinci bölümde ise hidroelektrik üretimi ve ithal edilen enerji miktarı verileri incelenmiş ve veriler modelde kullanılarak modelin yapısına karar verilmiştir. Test verisi ile elde edilen tahminler gerçek verilerle karşılaştırılıp modelin performansı incelenmiştir. Bölüm sonucunda da hidroelektrik üretim tahmini ile ithal edilen enerjinin tahmini yapılmıştır.

Dokuzuncu ve son bölümde yapılan tahminler ışığında Türkiye'nin gelecekteki enerji politikası ve hidroelektrik üretimine dair çıkarımlar yapılmış, çalışmanın ve modelin sürdürülebilmesi için çeşitli öneriler getirilmiştir.

2. TÜRKİYE’NİN ENERJİ BAKIMINDAN DURUMU

Bir ülkede sürdürülebilir kalkınmanın sağlanabilmesi için uzun dönemde herhangi bir olumsuz sosyal etkisi olmayan ve kabul edilebilir düzeyde bir maliyete sahip enerji kaynaklarının arzının olması gerekir (Yüksek, 2006).

Geleneksel enerji kaynakları kömür, petrol ve doğal gazı içeren fosil yakıtları kapsar. Global iklim değişimlerinin, dünyadaki enerjinin ve enerji kaynaklarının kısıtlı olmasının dünya istikrarı üzerindeki tehdidi giderek artmaktadır. Özellikle fosil yakıtların kullanımının artmasından kaynaklanan bu problemler yerel, bölgesel ve global boyutlardadır. Fosil yakıtların kullanımı devam ettiği sürece bu problemlerin artacağı görülmektedir. Bu durum dünya nüfus artışı, hızlı gelişen teknoloji ve enerji talebinin artmasının sonucudur. Geçmişte fosil enerji kaynakları dünya enerji problemini çözmek için kullanılmıştı. Bugün dünyanın hızla artan enerji talebi ve enerji tüketimine fosil yakıtlar çözüm olamaz (Ermis ve diğ., 2006). Uzmanlar potansiyel ve ekonomik olarak kullanılabilir fosil enerji kaynaklarını ve gelecekteki enerji talebini karşılamak için ne kadar yenilenebilir enerji kullanılması gerektiğini belirlemelidirler (Ediger ve diğ., 2007).

Fosil yakıtların sebep olduğu en önemli problem katran, toz ve CO_x, SO_x ve NO_x gibi zararlı gazların atmosfere salınarak hava kirliliği yaratmasıdır. Fosil yakıtlar endüstriyel, konutsal, ticari ve ulaşım sektöründe oldukça fazla kullanım alanına sahiptir. Otomobil, gemi, ve uçak gibi taşıma araçlarında fosil yakıtların kullanımı hava kirliliğini artırmaktadır. İnsanların karşılaştığı en büyük çevresel problem olan küresel ısınma büyük ölçüde fosil yakıtlardan kaynaklanmaktadır. (Ermis ve diğ., 2006).

Yenilenebilir (yeşil) enerji fosil enerji kaynaklarına alternatiftir. Yirmi birinci yüzyılda yenilenebilir enerji tüketimi sosyal, endüstriyel, ekonomik ve teknolojik gelişimi belirleyen önemli bir parametredir. Ayrıca yenilenebilir enerji artışı gelişimin sürekliliğine katkıda bulunmaktadır. Bu yüzden yenilenebilir enerji, enerji güvenliği, sürekli gelişim ve sosyal, teknolojik, endüstriyel ve ekonomik gelişim için bir katalizör olarak görülebilir (Ermis ve diğ., 2006).

Global olarak enerji talebi, hızlı nüfus artışı, teknolojik ve sosyal gelişime bağlı olarak artmaktadır. Çeşitli sektörlerde büyük oranda fosil enerji kaynaklarının kullanılması çevre, insan sağlığı ve refahı için ciddi tehlike oluşturmaktadır. Fosil yakıtların kullanımı yüzünden oluşan problemleri azaltmak için fosil enerji tüketiminin kısıtlanması ve yenilenebilir enerji kullanımının teşvik edilmesi gerekmektedir. Nüfusun hızla artması beklendiği için fosil yakıtların tüketiminin de hızla artması beklenmektedir. Bu yüzden fosil enerji kaynakları korunmalı ve iyi yönetilmelidir ve fosil yakıt tüketim tahminleri dikkatli yapılmalıdır (Ermis ve diğ, 2006).

Türkiye dünya nüfusunun %1,12'sini oluşturmaktadır (Tablo 2.1). Dünya' daki enerji tüketiminin % 0,93'ünü Türkiye gerçekleştirmektedir. Kişi başına enerji tüketimi 1270 kep (kg eşdeğeri petrol) karşılığı 57 GJ (milyar Joule) ile dünya ortalamasının altındadır. Bir ülkenin enerji tüketiminin giderek artması özellikle gelişmekte olan ülkeler için sanayileşmenin artması anlamına gelir. Bu açıdan bakıldığında enerji tüketimi ülkeler için ekonomik bir gelişme göstergesidir. Türkiye'nin ekonomisi özellikle 1982 ve sonrasında tarıma dayalı ekonomiden endüstriye dayalı ekonomiye doğru hızlı bir değişime uğramıştır. Fakat endüstrileşme süreci hala tamamlanmış değildir (Ediger ve Huvaz, 2006). Ekonomik üretime bakıldığında da Türkiye'nin dünya ortalamasının altında olduğu görülmektedir. Dünya'da kişi başına düşen gayrisafi hasıla 5470\$ iken Türkiye'de 5000\$'dır. Ekonominin enerji yoğunluğu enerji kullanımının verimi ve ekonominin enerjiye ne ölçüde bağlı olduğu hakkında bilgi verir. Türkiye'de ekonominin enerji yoğunluğu 0,25 kep/\$ ile dünya ortalamasının altındadır. Bu oran birim üretim başına tükettiğimiz enerjinin ölçüsüdür ve az olması istenen bir durumdur. Çünkü ekonominin enerji yoğunluğu ile kişi başına gelir arasında ters yönlü bir ilişki vardır. Her ne kadar enerji yoğunluğu açısından Türkiye'nin dünya ortalamasının altında olması istenen bir durum olsa da bu oran gelişmiş ülkelerin enerji yoğunluk oranlarından fazladır. Gelişmiş OECD (Organisation for Economic Co-operation and Development) ülkelerine bakıldığında Türkiye'nin ekonomisinin enerji yoğunluk oranının yüksek olduğu söylenebilir. Örneğin, İsviçre için bu oran 0,08 kep/\$'dır (Altın, 2007).

Tablo 2.1: 2005 Yılında Türkiye ve Dünya’da Enerji Tüketimi ve Gayrisafi Milli Hasıla (Altın, 2007)

	Nüfus (Milyon)	ENERJİ TÜKETİMİ (2005)				GAYRİSAFİ MİLLİ HASILA(2005)		
		Toplam		Kişi başına yıllık		Toplam Milyar (\$)	Kişi başına (\$)	Ekonominin elektrik yoğunluğu (kep/\$)
		Milyon ton eşdeğeri petrol (mtep)	Egza Joule (1018 Joule)	Kg eşdeğeri petrol (kep)	Milyar Joule (GJ)			
DÜNYA	6400	9800	441	1530	70	35000	5470	0,28
TÜRKİYE	72	91,5	4,1	1270	57	360	5000	0,25
Türkiye’nin Dünya’daki payı	1,12%	0,93%	0,93%	1,07%	0,95%	1,03%	91%	117%

Tablo 2.2: 2006 Yılında Elektrik Üretimi, Kurulu Güç ve Gayrisafi Milli Hasıla (Altın, 2007)

	Nüfus (Milyon)	ELEKTRİK ÜRETİMİ		KURULU GÜÇ		GAYRİSAFİ MİLLİ HASILA		
		Toplam GkWh (milyar kWh)	Kişi başına ortalama yıllık,kWh	Toplam, GW	Kişi başına W.	Toplam Milyar \$	Kişi başına \$	Ekonominin elektrik yoğunluğu kWh/\$
DÜNYA	6400	14300	2234	3641	569	35000	5470	0,41
TÜRKİYE	72	173,1	2400	38,8	539	360	5000	0,48
Türkiye’nin Dünya’daki payı	1,12%	1,21%	1,07%	1,07%	0,95%	1,03%	91%	117%

Türkiye'deki enerji üretimine bakıldığında çok düşük bir seviyede olduğu görülür. Enerji ihtiyacının %52'si ithalatla karşılanmaktadır ve ithalatın oranı giderek artmaktadır. OECD ülkeleri arasında Türkiye'nin 1995'te %2 olan üretim oranının 2020'de %7'ye çıkması beklenmektedir (Sözen ve diğ, 2005).

Türkiye'nin birincil enerji kaynakları kömür, linyit, asfaltit, hidrolik, petrol, doğalgaz, jeotermal, güneş enerjisi ve hayvan-bitki artıklarıdır. Kömür halen en büyük yakıt kaynağıdır ve enerji kullanımının yarısını petrol ve doğalgaz oluşturur. Doğalgaz enerji kullanımında %12'lik paya sahipken, petrol %44'le en büyük paya sahiptir. Ancak doğalgaz ve petrol rezervleri oldukça sınırlıdır. Petrol ve doğalgazın birincil enerji üretimindeki payları sırasıyla %13 ve %1'dir. Linyit ise birincil enerji üretiminin %43'ü ile en büyük paya sahiptir (Sözen ve diğ, 2005).

Enerji talebindeki hızlı artış Türkiye'yi yabancı enerji tedarikçilerine bağımlı hale getirmektedir ve 21. yüzyılda enerji kıtlığı olasılığını doğurmaktadır. (Sözen ve diğ, 2005). Türkiye'nin ithal kaynaklara olan bağımlılığı gelişiminin istikrarı açısından önemli bir engeldir (Ediger ve Huvaz, 2006). Türkiye ithalci konumdan çıkmak için geleneksel enerji kaynaklarını kullanmak yerine yenilenebilir enerji kaynaklarını kullanmalıdır (Ediger ve Kentel, 1999). Türkiye'de yenilenebilir enerji kaynaklarının çok zengin olmasına ve ülkenin enerji ihtiyacının önemli bir kısmını karşılayabilecek bir potansiyele sahip olmasına karşın yerli ve yenilenebilir enerji kaynakları ya hiç kullanılmamakta ya da potansiyelin çok altında değerlendirilmektedir (TMMOB, 2005).


Türkiye'nin ekonomisinde enerji ve ekonomi ilişkisinin gelişimini hükümet politikaları belirlemektedir. Bu politikalar enerji talebindeki değişimleri de içermelidir (Ediger ve Huvaz, 2006). Üretim kaynaklarının çeşitlendirilmesi ülkelerin enerji gereksinimlerinin karşılanmasında büyük bir öneme sahiptir (Ünsal ve Önöz, 2006). Uzun dönem enerji talebinin karşılanmasında Türkiye hükümeti ve özel sanayi birincil enerji kaynaklarına yatırım yapmaktadırlar. Oysa, yüksek sermaye maliyetine rağmen Türkiye'de rüzgar enerjisini kullanmanın avantajları vardır. Türkiye'de güçlü ve sürekli rüzgar akımlarının olduğu bazı bölgeler bulunmaktadır. Bu yüzden rüzgar enerjisi konusunda büyük bir ilgi vardır ve bir an önce uygulamak için çok ciddi çalışmalar yürütülmektedir (Demirbaş, 2002). Rüzgar enerjisi Türkiye'nin elektrik üretimi problemi için en uygun çözüm olarak görülmektedir (Topcu ve diğ, 2004).

Enerji üretimindeki en dikkat çekici gelişme hidro ve jeotermal enerjide görülmektedir (Demirbaş, 2002). Türkiye, en önemli yenilenebilir enerji kaynağı olan hidroelektrik potansiyeli bakımından oldukça zengindir (Ünsal ve Önöz, 2006). Hidroelektrik santraller elektrik üretimindeki en verimli yol olmaya devam etmektedir. Modern hidro tribünler enerjinin %90'ını elektriğe dönüştürebilmektedirler. Oysa en iyi fosil yakıt kaynakları bile %50 verimle çalışmaktadırlar (Yüksek, 2006). Tüm bu avantajlarına ve ülke potansiyeline rağmen Türkiye'nin hidroelektrik potansiyelinin 2/3'ü henüz değerlendirilmemektedir (Ünsal ve Önöz, 2006).

2000 yılında yürürlüğe giren “Yenilenebilir Enerji Kaynaklarının Elektrik Enerjisi Üretimi Amaçlı Kullanımına İlişkin Kanun” yenilenebilir enerji kaynaklarına ilişkin bazı teşvikleri içermekte ve özel sektörün de yatırım yapmasına olanak sağlamaktadır. Bu kanunla birlikte çevre dostu olan ve özellikle sera gazlarının azaltılmasına katkıda bulunan yenilenebilir enerji kaynaklarının kullanımının yaygınlaşması beklenmektedir. İklim Değişikliği Çerçeve Sözleşmesine ilişkin olarak 1997 yılında imzaya açılan Kyoto Protokolü Türkiye tarafından henüz imzalanmamıştır (DEK-TMK, 2004).

Türkiye'deki 2006 yılı elektrik üretim planına bakıldığında (Tablo 2.2) dünya'daki toplam elektrik üretiminin %1,21'i Türkiye tarafından gerçekleştirilmesi hedeflenmiştir. Kişi başına düşen elektrik üretimi de dünya ortalamasının üzerindedir. Dünyadaki toplam kurulu gücün %1,07'sini oluşturan Türkiye kişi başına kurulu güçte dünya ortalamasının altındadır. Ekonominin elektrik yoğunluğuna bakıldığında ise Türkiye'de bu oran dünya ortalamasının %17 üzerindedir. Türkiye ekonomik olarak büyümedikçe bu oranın düşmesi beklenemez. Tablo 2.2'de de görüldüğü gibi Türkiye elektrik üretiminde kişi başına 2400 kWh ile dünya ortalamasının üzerindedir ancak OECD ülkeleri arasında sonuncudur (Altın, 2007).

Şekil 2.1'de Türkiye'deki 2006 yılı elektrik üretiminde kullanılan birincil enerji kaynakları ve kullanım oranları görülmektedir. 2006 yılı için elektrik üretiminin %77'sinin termik, %23'ünün hidrolik kaynaklardan sağlanmıştır. Termik kaynaklardan üretimin 75,8'i doğalgaza, 10,2'si ithal kömüre, 5'i motorine, 2,9'u nafta ve LPG'ye olmak üzere 93,9 GWh'i ithal kaynaklara dayalıdır. Bu durumda termik kaynaklardan üretilen elektriğin %70'i, toplam elektrik üretiminin ise % 54'ü ithal kaynaklardan sağlanmaktadır. Yerli kaynaklar toplam elektrik üretiminin %46'sında yer alırken, ithal kaynaklar %54'ünde yer almaktadır.



Şekil 2.1: 2006 yılı elektrik üretiminin birincil enerji kaynaklarına göre dağılımı

3. TÜRKİYE’DE YAPILAN ENERJİ TAHMİN ÇALIŞMALARI


Tahmin doğru karar vermeyi, rekabet avantajı yaratmayı ve gelecekte oluşabilecek sürprizlerden kaçınmayı sağlar. Enerji kaynaklarının gelişimi, kullanımı ve dağıtımı, tahmin modelleri için oldukça geniş bir kullanım alanı olmaktadır (Utgikar ve Scott, 2006). Enerji, üretimin temel girdisidir ve tüm dünyada olduğu gibi Türkiye’de de ekonomik ve sosyal gelişme için önemli bir faktördür (Sözen ve diğ., 2005).

Enerji modelleme bilim adamları ve mühendisler arasında son zamanların ilgi çeken konularındandır. Enerji planlama, gelecek tahminlerinin bilinmesini gerektirdiği gibi, geçmiş ve gelecek enerji tüketimleri arasındaki nedensel ilişkiyi bilmeden gerçekleşemez. Türkiye’de enerji talebinin planlanması ve tahmininde istatistiksel yöntemler 1980’lerden bu yana yaygın olarak kullanılmaktadır (Sözen ve diğ., 2005).

Enerji tüketiminin tahmini geleceğe dair enerji planlamalarında önemli bir faktördür. Şekil 3.1 enerji planlamasının önemini göstermektedir. Şekilde kesikli çizgiyle gösterilen bölüm planlamanın yapılmadığı veya eksik yapıldığı durumda oluşan sonuçları, sürekli çizgiyle gösterilen bölüm ise iyi bir planlamanın getireceği faydaları göstermektedir. Yerel ve endüstriyel uygulamalarda fosil ve yenilenebilir enerji tüketimi projeleri önemlidir ve geleceğin enerji strateji, politika, yatırım ve planlamasında önemli bir rol oynamaktadır. Yenilenebilir enerjiye geçişin belirlenmesi ve bütçe planlaması da yerel ve endüstriyel yatırımlar için önemlidir. Türkiye birincil enerji tüketiminde fosil yakıtların payını azaltmak için yeni uzun dönemli enerji stratejileri geliştirmelidir (Demirbaş, 2002). Enerji uzmanları fosil yakıtların potansiyelini ve ekonomik olarak kullanılabilirliğini ve gelecekte dünya enerji ihtiyacını karşılamak için yenilenebilir enerjilerin ne kadar kullanılması gerektiğini tahmin etmeleri gerekmektedir (Ermis ve diğ., 2006). Ülkenin hedeflenen ekonomik büyüme ve sosyal gelişimine dayanan orta ve uzun dönemli birincil enerji talep tahminlerinin gerçekçi tahmin edilmesi bu hedeflerin gerçekleşmesinde önkoşuldur (Sözen ve diğ., 2005).

Yenilenebilir enerji üretiminde hem dünya hem de Türkiye için teknoloji henüz ileri boyutlara gelmese de fosil yakıtların kısıtlı ve tükenecek olması açısından

yenilenebilir enerjinin Türkiye ve dünya açısından önemli rol oynayacağı açıktır (Ediger ve Kentel, 1999).



Şekil 3.1: Enerjinin planlanması ve tahmin edilmesi (Ermis ve diğ., 2006)

2000-2007 yılları arasında Türkiye’de enerji konusunda yapılan tahmin çalışmaların özeti Tablo 3.1’de gösterilmektedir. Yapılan çalışmaların büyük bir bölümü fosil yakıtlarla ilgilidir.

Tablo 3.1: 2000-2007 yılları arasında Türkiye’de enerji tahmini konusunda yapılan çalışmalar

TARİH	ÇALIŞMANIN YAZARLARI	KULLANILAN YÖNTEM	VERİ	HEDEF	TAHMİN EDİLEN YILLAR	SONUÇ
2007	Toksarı	Karınca Kolonileri	1979-2005	Türkiye'nin enerji talep tahmini	2006-2025	Karınca kolonileri enerji tahmininde alternatif bir model olarak kullanılabilir.
2007	Ediger ve Akar	ARIMA	1950-2004	Türkiye'nin birincil enerji talep tahmini	2005-2020	Birincil enerji talebindeki yıllık artış oranı 2005-2020 arasında azalma gösterecektir. Fosil yakıtlar gelecekte de Türkiye için önemli bir rol oynayacaktır. Önerilen model görece tahmin hatası az çıkmıştır, enerji tahmininde alternatif bir model olarak kullanılabilir.
2006	Murat ve Ceylan	Yapay Sinir Ağı	1970-2001	Türkiye'nin taşımacılık enerji talep tahmini	2002-2020	Petrol talep tahmininde önerilen GA modeli alternatif bir yöntem olarak kullanılabilir.
2006	Canyurt ve Öztürk	Genetik Algoritma	1975-2003	Türkiye'nin petrol talep tahmini	2004-2020	2015 yılında endüstriyel elektrik tüketimi 140,37 TWh ve toplam elektrik tüketimi 165.5 TWh olacak.
2006	Akay ve Atak	Gri tahmin yöntemi (Grey prediction)	1970-2004	Türkiye'nin elektrik talep tahmini	2006-2015	Türkiye'nin hidroelektrik potansiyeli 2020 yılı itibarıyla elektrik enerjisi talebinin %33-46'sını karşılayabilecek ve bu oran artış gösterecektir.
2006	Yüksek ve diğ.	Benzetim modeli (MAED)	1990-2003	Türkiye'nin uzun dönem elektrik talebi ve hidroelektrik potansiyeli tahmini	2004-2020	Fosil yakıtların tüketimi giderek artarken üretiminin azalacağı gözlenmektedir.
2006	Ediger ve diğ.	Regresyon ve ARIMA	1950-2003	Fosil yakıt kaynaklarının üretim tahmini	2004-2038	YSA'nın enerji tüketimi tahmininde başarılı sonuçlar vermiştir.
2005	Sözen ve diğ.	Yapay Sinir Ağı	1975-2003	Türkiye'nin net enerji tüketimi tahmini	Tahmin yapılmamıştır	Güneş potansiyelinin tahmininde YSA klasik regresyon tekniklerine göre daha iyi sonuçlar elde etmiştir.
2005	Sözen ve diğ.	Yapay Sinir Ağı	2000-2003	Türkiye'nin güneş potansiyeli tahmini	Tahmin yapılmamıştır	Konutsal enerji tüketiminin tahmininde önerilen GA modeli alternatif bir yöntem olarak kullanılabilir.
2005	Canyurt ve diğ.	Genetik algoritma	1995-2002	Türkiye'nin konutsal enerji tüketimi tahmini	2003-2023	

Tablo 3.1: (devamı)

2005	Öztürk ve diğ.	Genetik Algoritma	1980-2001	Türkiye'nin elektrik tüketimi tahmini	2002-2025	Elektrik üretiminin tahmininde önerilen GA modeli alternatif bir yöntem olarak kullanılabilir.
2005	Haldenbilen ve Ceylan	Genetik algoritma	1970-2000	Türkiye'nin taşımacılık enerji talep tahmini	2002-2020	Taşımacılık enerji talep tahmininde önerilen GA modeli alternatif bir yöntem olarak kullanılabilir.
2004	Görücü ve diğ.	Yapay Sinir Ağı	1991-2001	Ankara'nın gaz tüketimi tahmini	2002 ve 2005	Bir önceki dönemin değeri de modele katıldığı için YSA özellikle kısa dönemli tahminde daha iyi sonuçlar vermiştir.
2004	Ceylan ve Öztürk	Genetik algoritma	1970-2001	Türkiye'nin enerji talep tahmini	2002-2025	Enerji üretiminin tahmininde önerilen GA modeli alternatif bir yöntem olarak kullanılabilir.
2004	Öztürk ve diğ.	Genetik Algoritma	1990-2000	Petrol enerji talep tahmini	2001-2020	GA, petrol enerji talebinin tahmininde alternatif bir yöntem olarak kullanılabilir.
2004	Yumurtacı ve Asmaz	Çok değişkenli regresyon modeli	1980-2002	Türkiye'nin elektrik talep tahmini	2003-2050	Yenilenebilir enerji kaynakları 2050 yılına kadar 360 milyar kWh enerji üretmek üzere kullanılmalıdır.
2004	Görücü ve Gümrah	Çok değişkenli regresyon modeli	1991-2001	Ankara'nın gaz tüketimi tahmini	2002 ve 2005	İyimser ve kötümser 2 farklı senaryo için önerilen model tahminde başarılı sonuçlar vermiştir.
2004	Aras ve Aras	Autoregressive zaman serisi modeli	1996-2001	Türkiye'nin aylık doğalgaz talep tahmini	tahmin yapılmamıştır	Önerilen model aylık doğalgaz talebinin tahmininde başarılı sonuçlar verdiği görülmüştür.
2003	Sarak ve Satman	Derece-gün (degree-day) yöntemi	1990-1997	Türkiye'deki konutsal doğal gaz talep tahmini	2000-2023	Türkiye'nin 2023 yılında konutsal doğalgaz talebi 14,92 Gm ³ olacaktır.
2002	Ediger ve Tatlıdıl	Winters'ın üstel düzeltme yöntemi	1950-1999	Türkiye'deki birincil enerji talep tahmini	2000-2010	2010 yılında Türkiye'nin enerji tüketiminin 130 milyon toe'yu bulacak
2000	Durmayaz ve diğ.	Derece-saat (degree-hours) yöntemi	1990-1997	İstanbul'un konutsal ısınma ihtiyacı ve fosil yakıt tüketimi	tahmin yapılmamıştır	Hava kirliliği yüksek olan şehirlerde fosil yakıt tüketiminin ve alternatif enerjilerin kullanımının planlanması açısından konutsal ısınma ihtiyacının tahmini önem taşımaktadır.

Durmayaz ve diğ. (2000), İstanbul'un konutsal ısınma ihtiyacını tahmin etmişlerdir. İstanbul gibi hava kirliliğinin yüksek olduğu şehirlerde fosil yakıt tüketiminin ve alternatif enerjilerin kullanımının planlanması açısından konutsal ısınma ihtiyacının tahmini önem taşımaktadır.

Ediger ve Tatlıdil (2002), Türkiye'deki birincil enerji talebini Winters'ın Üstel Düzeltme yöntemini uygulayarak tahmin etmişlerdir. 2010 yılında Türkiye'nin enerji tüketiminin 130 milyon ton eşdeğer petrolü bulacağı sonucuna varmışlardır.

Sarak ve Satman (2003), derece-gün (degree-day) metodu ile Türkiye'deki konutsal doğal gaz talebini tahmin etmişler ve test tahminleri gerçek değerlerle karşılaştırıldığında sonuçlar yeterli görülmüştür. Türkiye'nin 2023 yılında (tüm konutların doğalgaz kullanacağı varsayımı altında) konutsal doğalgaz talebinin 14,92 Gm³ olacağı görülmüştür.

Aras ve Aras (2004) Türkiye'nin aylık doğalgaz talep tahmini için bir otoregresif zaman serisi modeli geliştirmişlerdir. Önerilen model basit tahmin teknikleriyle karşılaştırılmış ve aylık doğalgaz talebinin tahmininde başarılı sonuçlar verdiği görülmüştür.

Görücü ve Gümrah (2004) iyimser ve kötümser iki senaryo için Ankara'nın gaz tüketimini tahmin etmişlerdir. Kullandıkları çok değişkenli regresyon modeli başarılı sonuçlar vermiştir.

Yumurtacı ve Asmaz (2004) Türkiye'nin elektrik talep tahmininde çok değişkenli regresyon modeli kullanmışlardır. Bulunan sonuçlara göre Türkiye'nin enerji ihtiyacı 2050 yılında 1,173 milyar kWh olacaktır. DSİ'ye göre ekonomik kullanılabilir hidroelektrik potansiyelimiz 125 milyar kWh'tir ve yıllık termal enerji üretimi 688 milyar kWh'tir. Sonuç olarak Türkiye 360 milyar kWh'i diğer enerji kaynaklarından üretilmelidir. Bu değerlere göre yenilenebilir enerji kaynakları 2050 yılına kadar 360 milyar kWh enerji üretmek üzere kullanılmalıdır.

Öztürk ve diğ. (2004) petrol enerji talep tahmini için genetik algoritmaların kullanıldığı 3 ayrı talep tahmin modeli geliştirmişlerdir. Aynı modeli Ceylan ve Öztürk (2004) Türkiye'nin enerji talep tahmininde, Haldenbilen ve Ceylan (2005) Türkiye'nin taşımacılık enerji talep tahmininde, Öztürk ve diğ. (2005) Türkiye'nin elektrik tüketimi tahmininde, Canyurt ve diğ.(2005) Türkiye'nin konutsal enerji tüketimi tahmininde, Canyurt ve Öztürk (2006) Türkiye'nin petrol talep tahmininde

kullanmışlardır. Tüm çalışmalarda bulunan tahmin değerleri Türkiye Enerji ve Doğal Kaynaklar Bakanlığının tahmin sonuçları ile karşılaştırılmış ve önerilen modelin görelî tahmin hatası daha az çıkmıştır. Çalışmaların sonucunda genetik algoritmaların enerji tahmininde alternatif bir yöntem olarak kullanılabileceğî görülmüştür.

Görücü ve diğ. (2004) 2 farklı senaryo için Ankara'nın gaz tüketimi tahmini üzerine çalışmışlardır. Modelde yapay sinir ağıları kullanılmıştır ve tahmin başarılı sonuçlar vermiştir. Bir önceki dönemin değeri de modele katıldığı için yapay sinir ağıları özellikle kısa dönemli tahminde daha iyi sonuçlar vermiştir.

Sözen ve diğ. (2005-a) Türkiye'nin net enerji tüketimini yapay sinir ağı ile tahmin etmiştir. Yapay sinir ağının enerji tüketimi tahmininde başarılı sonuçlar verdiği görülmüştür. Yapay sinir ağı esnek bir yapıya sahip olduğu için ve enerji tüketiminde gelecek trendin nasıl olacağını yakalayabildiğî için tahmin modeli olarak kullanılması uygun bulunmuştur.

Sözen ve diğ. (2005-b) güneş enerjisinin potansiyelini yapay sinir ağıları ile tahmin etmişlerdir. Güneş potansiyelinin tahmininde yapay sinir ağıları klasik regresyon tekniklerine göre daha iyi sonuçlar elde etmiştir.

Ediger ve diğ. (2006) Türkiye'deki fosil kaynakların üretiminin tahmininde Regresyon ve ARIMA yöntemlerini kullanmışlardır. Çalışma sonucunda Hard kömür üretimi 2019'da, doğalgaz üretimi 2024'te, petrol üretimi 2028'de, asfaltit ve linyit üretimi 2038'de sona ereceğî görülmüştür. Bir başka sonuç ise fosil yakıtların tüketimi giderek artarken üretiminin azalacağıdır.

Akay ve Atak (2006) Türkiye'nin elektrik talebini yeni bir yaklaşım olan Gri Tahmin Yöntemi (Grey Prediction With Rolling Mechanism - GPRM) metoduyla tahmin etmişlerdir. Tahmin sonuçları Türkiye Enerji ve Doğal Kaynaklar Bakanlığının tahmin sonuçları ile karşılaştırılmış ve önerilen model daha iyi sonuç vermiştir. Çalışmanın sonuçlarına göre 2015 yılında Türkiye'nin endüstriyel elektrik tüketiminin 140,37 TWh ve toplam elektrik tüketiminin 165.5 TWh olması beklenmektedir.

Murat ve Ceylan (2006) Türkiye'nin taşımacılık enerji talebinin yapay sinir ağıları ile bulunan tahmin değerlerini Türkiye Enerji ve Doğal Kaynaklar Bakanlığının tahmin sonuçları ile karşılaştırılmış ve önerilen modelin görelî tahmin hatası daha az çıkmıştır. Yapay sinir ağlarının enerji tahmininde başarılı sonuçlar verdiğini vurgulamışlardır.

Yüksek ve diğ., (2006) Türkiye'nin hidroelektrik potansiyelini tahmin etmişlerdir. Tahmin yöntemi olarak "Enerji Talebini Değerlendirme Modeli (Model for Assessment of Energy Demand - MAED)" adlı bir benzetim modelini kullanmışlardır. Yapılan çalışma sonucunda hidroelektrik enerjinin elektrik üretiminde en verimli yol olmaya devam edeceği belirtilmiştir. 2020 yılında Türkiye'nin hidroelektrik potansiyeli enerji ihtiyacının %33-46'sını karşılayabilecek duruma gelmesi beklenmektedir.

Ediger ve Akar (2007) ARIMA ile Türkiye'nin birincil enerji talebini tahmin etmişlerdir. Çalışma sonuçlarına göre birincil enerji talebindeki yıllık artış oranı 2005-2020 arasında azalma gösterecektir. Fosil yakıtlar gelecekte de Türkiye için önemli bir rol oynayacaktır. 2012'de petrol yerini doğalgaza bırakacak ve 2020'de doğalgazın toplam enerji tüketimindeki payı %42 olacaktır. En az oranda artma ise linyitte olacaktır.

Toksarı (2007) Türkiye'nin 2006-2025 yılları arası enerji talebini karınca kolonileri yaklaşımı ile tahmin etmiştir. Doğadaki karıncaların gözlemlenmesinden ortaya çıkan karınca kolonileri, yiyecek toplama prensibini dikkate alan biyoloji biliminden esinlenerek geliştirilmiş bir meta sezgisel yöntemdir. Karınca kolonileri enerji talep tahmin modelinde nüfus, gayri safi milli hasıla, ihracat ve ithalat verileri kullanılmıştır. Bulunan sonuçlar Türkiye Enerji ve Doğal Kaynaklar Bakanlığının tahmin sonuçları ile karşılaştırılmış ve önerilen modelin göreceli hata değeri daha küçük çıkmıştır. Çalışma sonucunda karınca kolonileri modeli enerji tahmininde alternatif bir tahmin modeli olarak önerilmiştir.

2000-2007 yıllarında yapılan çalışmaların geneline bakıldığında fosil yakıtların tüketimi giderek artarken üretiminin azalacağı ve yakın gelecekte sona ereceği gözlenmektedir (Ediger ve diğ., 2006). Bu durum yenilenebilir enerji üretiminin önemini vurgulamaktadır. 2000-2007 yılları arasında yapılan enerji tahmin çalışmalarından sadece iki çalışma yenilenebilir enerji ile ilgilidir. Bu çalışmalar da Yüksek ve diğ. (2006)'nin hidroelektrik potansiyeli tahmini ile Sözen ve diğ. (2005)'nin güneş potansiyeli tahmin üzerine yaptıkları çalışmalardır. Yenilenebilir enerji üretiminin tahminine yönelik bir çalışmaya 2000-2007 tarihleri arasında literatürde rastlanmamaktadır.

Tablo 3.1’de de görüldüğü gibi enerji tahmininde, klasik istatistiksel teknikler yerini genetik algoritma ve yapay sinir ağları gibi alternatif tekniklere bırakmaktadır. Uzmanların geleneksel istatistiksel yöntemler yerine genetik algoritma ve yapay sinir ağlarını tercih etme nedenleri şu şekilde sıralanabilir (Sözen ve diğ., 2005):

- ◆ Geleneksel istatistiksel yöntemler uygulanırken bazı varsayımların sağlanması gerekmektedir. Oysa genetik algoritmalar ve yapay sinir ağlarının uygulanması için herhangi bir varsayıma gerek yoktur.
- ◆ Genetik algoritmalar ve yapay sinir ağları klasik yöntemlerin çözemediği karmaşık problemleri çözebilmektedir.

Yapay Sinir Ağları enerji tüketiminin tahmininde önemli bir araçtır. YSA yaklaşımı bir çok araştırmada kullanılmasına rağmen enerji tüketiminin tahmininde literatürde sınırlı sayıda çalışmaya rastlanmaktadır (Ermis ve diğ., 2006).

4. ÇALIŞMANIN AMACI

Elektrik enerjisi üretim için gerekli olan girdilerden biri olarak büyük bir önem arz etmektedir. Elektrik üretilir üretilmez tüketilmesi gereken ve depolanamayan bir enerji çeşidi olduğu için, diğer enerji kaynaklarından farklılıklar göstermektedir. Mevcut teknolojilerle elektriğin depolanması ve daha sonraki ihtiyaçları karşılamak amacıyla kullanılması mümkün değildir. Bu nedenle taleple üretimin birbirine en uygun şekilde senkronize edilmesi gerekmektedir (ETKB, 2004).

Türkiye’de hidrolik enerji potansiyelinin %57’si, rüzgar enerji potansiyelinin %85’i, jeotermal enerji potansiyelinin %95’i kullanılmamaktadır. Benzer şekilde sınırsız enerji kaynağı olan ve Türkiye’nin tüm bölgelerinin sahip olduğu güneş enerjisinden faydalanılmamaktadır (TMMOB, 2005). Elektrik enerjisi üretiminin %54’ünün ithal kaynaklara dayalı olması, kullanılmayan yenilenebilir enerji potansiyelinin önemini gözler önüne sermektedir.

Çalışmanın ilk amacı Türkiye’nin en büyük yenilenebilir enerji potansiyeli olan hidroelektrik enerjinin gelecekteki üretim (tüketim) miktarını verecek bir tahmin modeli oluşturmak ve sonuçlardan hareketle Türkiye’nin potansiyelinin ne kadarını kullanacağını belirlemektir. Aynı zamanda Türkiye’de kullanılan ithal enerji kaynaklarının gelecek değerleri belirlenecek ve bulunan sonuçlar ithalata yönelik politika geliştirilmesinde ve hidroelektrik santrallerine yapılan yatırımların planlanmasında bir karar destek sistemi rolü oynayacaktır.

Çalışmada kullanılacak yöntem olarak yapay sinir ağları yaklaşımı tercih edilmiştir. Hidroelektrik üretiminde yapay sinir ağlarının kullanıldığı bir tahmin modeline literatürde rastlanmamaktadır. Yapay sinir ağlarının kullanıldığı yenilenebilir enerji konuları genel olarak güneşle çalışan jeneratörlerin ve su ısıtma sistemlerinin modellenmesi, fotovoltaiik sistemler ve güneş radyasyonu ve rüzgar hızı tahminleri olarak özetlenebilir. Bu çalışmalarda bulunan sonuçlardan hareketle yapay sinir ağlarının diğer yenilenebilir enerji konularında da başarılı sonuçlar verebileceği düşünülmektedir (Kalogirou, 2001).


Çalışma yapay sinir ağlarını yeni bir uygulama alanında kullanmayı hedeflemektedir. Ayrıca yapay sinir ağının kullanıldığı uygulamalarda yaşanan problemlerden hareketle, yine doğal sistemlerden esinlenen genetik algoritmalar kullanılarak yapay sinir ağının performansını artıran özgün bir hibrid model geliştirilmesi hedeflenmiştir. Önerilen bu modelle sadece enerji tahmini için değil diğer zaman serisi analizleri için de yeni bir araç geliştirilmiş olacaktır.

5. YAPAY SİNİR AĞLARI

5.1. Yapay Sinir Ağlarına Giriş

Yapay Sinir Ağları (YSA) beyin ve biyolojik sinir sistemlerinden esinlenen bir bilgi işleme algoritmasıdır (Azadeh ve diğ., 2006). YSA'nın yapısı sinir hücrelerinin yapısına benzemektedir. Her sinir hücresi *sinaps* denilen özel bağlantılarla diğer sinir hücrelerinden elektrokimyasal sinyaller alırlar. Bazı girdiler sinir hücresini iletmek üzere uyarırken bazıları iletilemezler. Eğer bir hücreyi dürtüleyen toplam etki eşik değerinin üzerindeyse hücre uyarılır ve iletim gerçekleşir; eğer eşik değerinin altındaysa iletim gerçekleşmez. Bir yapay sinir ağı genel olarak bu biyolojik yapının modellenmesidir (Fu, 1994).


Yapay sinir ağlarının genel gelişimi Şekil 5.1'de görülmektedir. 1940'lı yıllar ilk yapay sinir hücresi modellerinin geliştirilmeye başlandığı yıllardır. 1949'lara gelindiğinde ağı öğrenmesi üzerinde çalışmalar yapılmıştır. İlk ve en önemli öğrenme algoritması Hebb tarafından 1949 yılında geliştirilmiştir. 1970'lere gelindiğinde tek katmanlı sinir ağlarının birçok problem üzerindeki yetersizlikleri görülmüş ve çok katmanlı ağlar üzerine çalışmalar hız kazanmıştır. Sinir ağları konusunda pek çok ağ yapısı ve öğrenme algoritmaları geliştirilmiştir. 1986 yılında ise çalışmaların oldukça büyük bir bölümünde yer alan ve bu çalışmada incelenecek olan geri yayımlı öğrenme algoritması geliştirilmiştir (Fu, 1994).



Şekil 5.1: Yapay Sinir Ağlarının tarihsel gelişimi

5.2. Tek ve Çok Katmanlı Algılayıcılar

Algılayıcı (Perceptron) 1958 yılında Rosenblatt tarafından ortaya konulan yapay sinir ağının en temel işlem birimidir. Gözetimli öğrenmeyi kullanan ilk yapay sinir ağıdır (Şahin, 2002). Şekil 5.2’de algılayıcının genel yapısı görülmektedir. Dışarıdan veya diğer algılayıcılardan gelen her $x_j \in R$, $j=1,2,...,d$, girdisini y çıktı değerine bağlayan $w_j \in R$ bağlantı ağırlıkları bulunur ve y çıktı değeri girdilerin ağırlıklandırılmış toplamlarından oluşur (Alpaydın, 2004).



Şekil 5.2: Örnek bir algılayıcı (Alpaydın, 2004)

Ağırlık, sinir ağındaki herhangi iki sinir hücresi arasındaki bağlantının gücünü gösterir (Rooij ve diğ., 1996). w_0 sabit değeri hata hücresi olan x_0 ’ın ağırlığıdır. Hata hücresi x_0 diğer hücrelerden farklı olarak her zaman +1 değerine eşittir (Şahin, 2002).

$$y = \sum_{j=1}^d w_j x_j + w_0 \quad (5.1)$$

Ağırlık ve değişkenleri $\vec{w} = [w_0, w_1, ..., w_d]^T$ ve $\vec{x} = [x_0, x_1, ..., x_d]^T$ vektörleri olarak yazılırsa, çıktı değeri

$$y = \vec{w}^T \vec{x} \quad (5.2)$$

olarak vektörel çarpım halinde yazılabilir. Girdi sayısı 1’e eşit ($d = 1$) olduğunda ve x değerleri kullanıcı tarafından girildiğinde eğimi w ve sabit terimi w_0 olan


$$y = wx + w_0 \quad (5.3)$$

denklemleri elde edilir. Buradan hareketle denilebilir ki bir girdi ve bir çıktısı olan algılayıcı doğrusal bir denklem oluşturur. Birden fazla girdi olduğunda ise doğrusal çizgi bir hiper düzleme (hyperplane) dönüşür ve çok değişkenli doğrusal bir denklem üzerine oturtulur.

Çıktı sayısının $K \geq 2$ olduğu durumda ise K tane algılayıcı bulunur (Şekil 5.3). Bu durumda da denklem 5.1 aşağıdaki şeklini alır.

$$y_i = \sum_{j=1}^d w_{ij} x_j + w_{i0} \quad (5.4)$$

x_j , $j=1,2,\dots,d$, girdi ve y_i çıktı değeridir. w_{ij} , x_j girdisinden y_i çıktısına olan bağlantı ağırlığıdır.




Şekil 5.3: K paralel algılayıcı (Alpaydın, 2004)

Algılayıcıların temel problemi sadece doğrusal olan problemlerde kullanılabilmesidir (Şahin, 2002). Örnek olarak Boolean Fonksiyonunu ele alalım. Fonksiyonun girdileri 0-1 ve çıktısı da fonksiyon doğruysa 1 yanlışsa 0'dır (Alpaydın, 2004). İki sınıflı bir sınıflandırma problemi olarak da düşünülebilir. AND fonksiyonun girdi ve çıktı değerleri Tablo 5.1'de gösterilmektedir. Şekil 5.4'de ise AND fonksiyonu için örnek bir algılayıcı ile algılayıcının grafiksel gösterimi bulunmaktadır.

Tablo 5.1: AND Fonksiyonunun girdi ve çıktıları (Alpaydın, 2004)


x_1	x_2	y
0	0	0
0	1	0
1	0	0
1	1	1



Şekil 5.4: AND Fonksiyonu gösteren örnek bir algılayıcı ve grafiksel gösterimi (Alpaydın, 2004)

Tablo 5.2: XOR Fonksiyonunun girdi ve çıktıları (Alpaydın, 2004)

x_1	x_2	y
0	0	0
0	1	1
1	0	1
1	1	0



Şekil 5.5: XOR Fonksiyonunun grafiksel gösterimi (Alpaydın, 2004)


Şekil 5.4’de de görüldüğü gibi AND fonksiyonu doğrusal ayrılabilen ve algılayıcı ile çözülebilen bir fonksiyondur. Oysa Şekil 5.5’de grafiksel gösterimi bulunan XOR problemi doğrusal olarak ayrılamaz. Aşağıdaki kısıtları sağlayan w_0 , w_1 ve w_2 değerleri yoktur ve bu durum da XOR fonksiyonunun doğrusal ayrılabilen bir fonksiyon olmadığını ispatlamaktadır (Alpaydın, 2004):

$$\begin{aligned} w_0 &\leq 0 \\ w_0 + w_2 &> 0 \\ w_0 + w_1 &> 0 \\ w_0 + w_1 + w_2 &\leq 0 \end{aligned}$$

Algılayıcıların doğrusal ayrılamayan problemlerdeki bu yetersizliği YSA çalışmalarına bir dönem ara vermiştir. 1986 yılında Rumelhart, Hinton ve Williams tarafından yapılan çalışmaların yayınlanması ve çok katmanlı algılayıcıların doğrusal ayrılabilir olmayan problemleri çözdüğünün ortaya çıkması ile YSA tekrar önem kazanmıştır (Şahin, 2002).

YSA’lar genel olarak iki yapıda incelenirler: (1) ileri beslemeli YSA ve (2) geri beslemeli YSA. İleri beslemeli YSA’da girdi katmandan alınan sinyaller çıktı katmana doğru tek yönde ilerlerler. Her hangi bir geri besleme yoktur. Uygulamalarda ileri beslemeli YSA daha çok kullanılır. En yaygın ileri beslemeli YSA da çok katmanlı algılayıcılardır (Azadeh ve diğ., 2006).


Tek katmanlı algılayıcıların sadece doğrusal olan problemleri çözmesi kısıtına bir önceki bölümde değinilmişti. Bu kısıt girdi ve çıktı katmanları arasında gizli katmanların yer aldığı çok katmanlı algılayıcılarda (multilayer perceptron) söz konusu olmamaktadır (Alpaydın, 2004). Çok katmanlı bir algılayıcı örneği Şekil 5.6’da görülmektedir. Girdi ve çıktı katmanları birer katmandan oluşurken, gizli katman bir veya daha çok sayıda katmandan oluşur. Her katmanda ne kadar sayıda sinir hücresi olduğu problemin yapısına göre farklılık gösterir.



Şekil 5.6: Örnek bir çok katmanlı algılayıcı (Kalogirou, 2001)

Tek bir gizli katmandan oluşan iki katmanlı bir sinir ağı Şekil 5.7’de verilmektedir. x girdi değeri ağı girilir ve ileri yönlü hareket takip edilerek gizli katmanın çıktısı olan z_h hesaplanır. Her gizli sinir hücresi tek başına bir algılayıcıdır ve hareket fonksiyonu kullanılarak ağırlıklar toplamından z_h değeri bulunur (Alpaydın, 2004).

$$z_h = f\left(\sum_{j=1}^d w_{hj}x_j + w_{h0}\right) \quad h = 1, \dots, H \quad (5.5)$$



Şekil 5.7: Tek çıktısı olan bir çok katmanlı algılayıcının yapısı

Çıktı değeri olan y değeri, gizli katmanın çıktısı olan z_h ’ı girdi değeri olarak alarak hesaplanır.

$$y_i = v_i^T z = \sum_{h=1}^H v_{ih} z_h + v_{i0} \quad (5.6)$$


Girdi katmanında olduğu gibi gizli katmanda da hata hücresi (z_0) bulunmaktadır ve değeri +1’dir. Hata hücresinin ağırlık değeri de çıktı denkleminin sabit terimini

oluşturmaktadır ve girdi değerleri hesaplanarak bulunmamıştır. Başka bir deyişle hata hücresi girdi hücrelerinden bağımsızdır.

Hareket fonksiyonu doğrusal olmama durumunu sağlayabilmek için kullanılır. Eğer gizli katmanın çıktıları doğrusal olursa gizli katmana ihtiyaç kalmaz çünkü bir doğrusal kombinasyonun doğrusal kombinasyonu başka bir doğrusal kombinasyonu verir. Bu durumda doğrusal olmama şartı sağlanmamış olur. Hareket fonksiyonu kullanılırsa çıktı değerleri doğrusal olmayan fonksiyon çıktılarının doğrusal kombinasyonu olur (Alpaydın, 2004).

$f(t)$ ile gösterilen hareket fonksiyonu nöronun çıktısını girdilerinin ağırlıklandırılmış toplamı olan t 'nin fonksiyonu olarak tanımlar (Haykin, 1999). Aşağıda 3 temel hareket fonksiyonu tipi anlatılmaktadır:

♦ **Eşik Fonksiyonu (Threshold Function):** Bu fonksiyona göre t negatif bir değerse fonksiyonun değeri 0, ve pozitif bir değerse fonksiyonun değeri 1'dir.



Şekil 5.8: Eşik fonksiyonunun grafiksel gösterimi

Eşik fonksiyonu 0 ve 1 dışında bir değer alamaz. Şekil 5.8'de gösterilen eşik fonksiyonunun matematiksel gösterimi (Haykin, 1999):

$$f(t) = \begin{cases} 1, & t \geq 0 \\ 0, & t < 0 \end{cases} \quad (5.7)$$

şeklindedir. Sonuç olarak eşik fonksiyonu uygulanan h hücresi için çıktı değeri

$$f(t_h) = \begin{cases} 1, & t_h \geq 0 \\ 0, & t_h < 0 \end{cases} \quad (5.8)$$

olur. Burada t_h girdilerin ağırlıklandırılmış toplamıdır:


$$t_h = \sum_{j=1}^d w_{hj} x_j + w_0 \quad (5.9)$$

Hareket fonksiyonunun negatif değerler almasına izin vermek bazı problemlerde kolaylık sağlayabilmektedir. Denklem (5.10) ile gösterilen hareket fonksiyonu 0-1 aralığındadır. Bazı hareket fonksiyonları -1 ile +1 aralığında olabilir.

$$f(t) = \begin{cases} 1, & t \geq 0 \\ 0, & t = 0 \\ -1, & t < 0 \end{cases} \quad (5.10)$$

♦ **Parçalı Doğrusal Fonksiyon (Piecewise Linear Function):** Şekil 5.9'da gösterilen parçalı doğrusal fonksiyonunun matematiksel gösterimi şu şekildedir (Haykin, 1999):

$$f(t) = \begin{cases} 1, & t \geq \frac{1}{2} \\ t + \frac{1}{2}, & -\frac{1}{2} \leq t \leq \frac{1}{2} \\ -1, & t \leq -\frac{1}{2} \end{cases} \quad (5.11)$$




Şekil 5.9: Parçalı doğrusal fonksiyonun grafiksel gösterimi

Bu tarz bir hareket fonksiyonu doğrusal olmayan bir forma yakınsama olarak da düşünülebilir (Haykin, 1999).

♦ **Sigmoid Fonksiyon:** Sigmoid fonksiyon yapay sinir ağı modellerinde en sık kullanılan hareket fonksiyonudur çünkü türevi alınabilen ve doğrusal olmayan bir fonksiyondur. Öğrenme aşamasında hareket fonksiyonun türevlenebilir olması önemlidir (Welstead, 1994). Lojistik fonksiyon sigmoid fonksiyon örneklerinden biridir ve (5.12)'deki gibi ifade edilir.

$$f(t) = \frac{1}{1 + \exp(-at)} \quad (5.12)$$

a sigmoid fonksiyonun eğim parametresidir. Sigmoid fonksiyon ve a 'nın büyüklüğüne göre değişimi Şekil 5.10'de görülmektedir.




Şekil 5.10: Sigmoid fonksiyonun grafiksel gösterimi

Eğim sonsuza yakınsadıkça sigmoid fonksiyon eşik fonksiyonuna yakınsamaktadır. Eşik fonksiyonu sadece 0 ve 1 değerini alabiliyorken sigmoid fonksiyonu 0 ve 1 arasında sürekli aralıkta bir değer alabilir (Haykin, 1999). Uygulamalarda sık kullanılan ve -1 ile +1 aralığında değerler alan bir başka sigmoid fonksiyonu da Şekil 5.11'de grafiği görülen hiperbolik tanjant fonksiyonudur.

$$f(t) = \tanh(t)$$


(5.13)



Şekil 5.11: Hiperbolik tanjant fonksiyonunun grafiksel gösterimi

- **XOR Probleminin Çözümü:**

Algılayıcılarla çözümü bulunamayan XOR probleminin çözümünü veren örnek bir çok katmanlı sinir ağı modeli Şekil 5.12'de görülmektedir (Haykin, 1999). Ağda tek gizli katman bulunmaktadır. Hücreler arasındaki bağlantı ağırlıkları şekil üzerinde belirtilmiştir. Hareket fonksiyonu olarak eşik fonksiyonu kullanılmıştır.



Şekil 5.12: XOR Probleminin çözümünü veren sinir ağı yapısı

XOR probleminde ilk girdi 0, ikinci girdi 1 iken çıktının 1 olması beklenir. Birinci gizli sinir hücresi için ağırlıklandırılmış toplamına eşik fonksiyonu uygulandığında gizli sinir hücresinin çıktısı aşağıdaki gibi olur.

$$f(0 * 1 + 1 * 1 + 1 * (-1,5)) = f(-0,5) = 0$$

Aynı işlem ikinci sinir hücresine uygulandığında

$$f(0 * 1 + 1 * 1 + 1 * (-0,5)) = f(0,5) = 1$$

elde edilir. İki gizli hücrenin çıktı değerleri çıktı hücresi için girdi değeri olacaktır. Buradan çıktı değeri

$$f(0 * (-2) + 1 * 1 + 1 * (-0,5)) = f(0,5) = 1$$

değeri bulunur. Bulunan değer $x_1 = 0$ ve $x_2 = 1$ olduğunda beklenen değerdir. Böylece istenilen sonuca ulaşılmış olur. Tablo 5.2’de yer alan x_1 ve x_2 girdi değerleri örnekteki ağı uygulandığında da beklenen değerlerin bulunduğu görülür. Sonuç olarak tek katmanlı bir yapay sinir ağı modelinin XOR problemini çözdüğü görülmektedir.

5.3. Yapay Sinir Ağlarında Öğrenme

Öğrenme, yapay sinir ağının parametrelerinin, ağın içinde bulunduğu çevre tarafından uyarılması yoluyla adapte edildiği bir süreçtir. Bu tanım aşağıdaki olaylar dizisini anlatmaktadır (Haykin, 1999):

1. Yapay sinir ağı çevresinden etkilenir.

2. Bu etki sinir ağının parametrelerinin değişiminin altında yatan nedendir.
3. Sinir ağı, iç yapısında değişimler meydana geldiği için çevreye yeni bir biçimde cevap verir.

Yapay sinir ağlarındaki öğrenme bir ödül ceza sistemine benzetilebilir. Bir veriye doğru bir yönde tepki verildiğinde ağırlıklar güçlendirilir. Eğer yanlış yönde bir tepki verilmişse ağırlıklar zayıflatılarak ağı farklı tepkiler vermesi gerektiği öğretilir. Başka bir deyişle ağ istenen çıktılar için kuvvetlendirilirken, istenmeyenler için cezalandırılmış olur (Şahin, 2002). YSA’da gözetimli öğrenme, gözetimsiz öğrenme ve karma öğrenme olmak üzere üç tip öğrenme biçimi vardır.

5.3.1. Gözetimli Öğrenme

Girdiler ve çıktılar arasındaki yapıyı öğrenmeyi konu alan regresyon ve sınıflandırma (classification) problemleri gözetimli öğrenme (supervised learning) problemleridir (Alpaydın, 2004). Uygulamalarda bir gizli katmana sahip yapay sinir ağı modellerinin sınırlı sayıda veriden oluşan ve sürekli fonksiyonları başarıyla öğrenebildiği görülmüştür. İkinci katman genellikle sürekli ancak bazı noktalarda bu sürekliliği bozan durumlar varsa kullanılabilir. Ancak birçok uygulamada tek katmanın yeterli olduğu ve fazla katman sayısının öğrenmeyi yavaşlattığı görülmektedir (Welstead, 1994).

“İleri beslemeli” terimi bilginin tek yönlü ve girdi katmanından çıktı katmanına doğru aktığının göstergesidir. Her bir katmanın çıktıları bir sonraki katmanın girdilerini oluşturur ve her düzeyin çıktıları kendi girdilerinin bir fonksiyonudur (Welstead, 1994).

Hareket fonksiyonu her bir sinir hücresinin çıktısının değerini belirler. Karmaşık problemler için hareket fonksiyonunun doğrusal olmaması önemlidir. Hareket fonksiyonunun şekli ağın genel performansına çok az etki ederken öğrenme hızına etkisi oldukça yüksektir (Şahin, 2002).

Öğrenme sürekli öğrenme (online learning) ve toplu öğrenme (batch learning) olmak üzere iki şekilde gerçekleşebilir. Sürekli öğrenmede veriler birer birer algoritmada eğitilir. Toplu öğrenme ise verilerin bütünüün eğitilmesi ile gerçekleşir. Toplu öğrenmede hata fonksiyonu öğrenme verilerinin tümünü kapsarken, sürekli öğrenmede veriyi tek başına ele alır. Toplu öğrenmede verinin bütünü modele

verildikten sonra eğitim başlar. Eğitim setindeki verilerin ağıdan her geçişine devir (epoch) denilir (Alpaydın, 2004).

5.3.2. Gözetimsiz Öğrenme

Gözetimli öğrenmede girdiler ve çıktılar biliniyorken aralarındaki yapıyı ortaya koymak hedeflenmektedir. Gözetimsiz öğrenmede (unsupervised learning) ise sadece girdiler bilinir, çıktılar bilinmez. Gözetimsiz öğrenmede amaç girdiler arasındaki düzeni belirlemektir. Girdi uzayı bir dokuya sahiptir ve incelendiğinde hangi yapıların daha sık tekrarlandıkları ve hangilerinin daha seyrek tekrarlandıkları bulunabilir. İstatistikte bu durum yoğunluk tahmini olarak geçmektedir (Alpaydın, 2004). Girdilerin dokusu belirlendikten sonra öğrenme gerçekleşmiş olur ve yeni bir girdinin hangi sınıfa ait olduğu belirlenebilir (Haykin, 1999).

Kümeleme (clustering) problemleri gözetimsiz öğrenmeye örnek olarak verilebilir. Kümeleme analizinin amacı veri grubundaki kümeleri belirleme veya verileri gruplandırmadır. Örneğin müşterilerinin demografik özelliklerini ve geliş sıklıklarını veri tabanında bulunduran bir firma, bu verilerden yola çıkarak müşterilerini gruplandırabilir (sık gelen müşteriler, seyrek gelen müşteriler vs.) ve müşteri profilini belirleyebilir (Alpaydın, 2004).

5.3.3. Karma Öğrenme

Bazı uygulamalarda sistemin çıktısı bir dizi harekettir. Böyle uygulamalarda hareketin tek başına iyi olması önemli değildir. Önemli olan hareket dizisinin hedefe ulaşmasıdır. Amaç hedefe ulaşan hareket dizisinin belirlenmesi ve bu dizinin geçmiş hareket dizilerinden öğrenilmesidir. Bu öğrenme yöntemine karma öğrenme (reinforcement learning) denilmektedir (Alpaydın, 2004). Dinamik programlama sıralı karar verme için matematiksel bir altyapı sunduğundan karma öğrenme dinamik programlamayla oldukça ilişkilidir (Haykin, 1999).

Karma öğrenmede gözetimsiz öğrenmede olduğu gibi kesin çıktılar ağa verilmez. Ancak çıktılar iyi ya da kötü olarak ayırt edilebilir ve ağa belirtilebilir. Çıktının iyi veya kötü olduğunu belirtmek öğrenme üzerinde bir denetim kuracağından bu yönüyle gözetimli öğrenmeye benzemektedir (Şahin, 2002).

Oyunlar karma öğrenmeye örnek olarak verilebilir. Oyunlarda tek bir hamle tek başına bir şey ifade etmez. Hamlelerin bütününe iyi sonuç vermesi istenir. Örneğin

satranç kuralları az olan fakat her durumda olası hamlelerin sayısının fazla olması nedeniyle de oldukça karmaşık bir oyundur (Alpaydın, 2004).

5.4. Geri Yayılmalı Algoritma

Uygulamalarda ileri beslemeli YSA'lar için en sık kullanılan öğrenme algoritması geri yayılmalı algoritmadır (Back-propagation Algorithm). Geri yayılmalı algoritma (GYA) bir gözetimli öğrenme algoritmasıdır ve bir gradyan inişi yöntemidir (Welstead, 1994). GYA'nın temel prensibi hata teriminin küçültülmesi için ağırlıkların düzeltilmesine dayanır. İleri beslemeli YSA sonucunda bulunan hata değerine bağlı olarak ağırlıklar son katmandan ilk katmana doğru güncellenirler. Öğrenme sondan başa doğru hata teriminin yayılması ile gerçekleştiği için geri yayılmalı denmektedir. (Haykin, 1999).

Tek çıktı değeri olan bir sinir ağının çıktı değeri

$$y^t = \sum_{h=1}^H v_h z_h^t + v_0 \quad (5.14)$$

bulunur. t örneğin indeksini gösterirken, z_h Denklem (5.5) ile bulunur. Beklenen değer ve çıktı değerinin farkının karesinden oluşan hata fonksiyonu

$$E = \frac{1}{2} \sum_t (r^t - y^t)^2 \quad (5.15)$$

İkinci katmandaki sinir hücreleri ile çıktı hücreleri arasındaki ağırlıkların değişiminin hesaplanmasında en küçük kareler yöntemi kullanılır ve aşağıdaki şekilde bulunur:

$$\Delta v_h = -\eta \frac{\partial E}{\partial v_h} = \eta \sum_t (r^t - y^t) z_h^t \quad (5.16)$$

η , öğrenme oranıdır, bir başka deyişle ağırlıkların güncelleştirilmesinde kullanılan adımın büyüklüğüdür. Ağırlıkların değişiminin ne kadar büyük olacağını ortaya koyar. (0, 1) aralığında bir değer alır. Negatif işaret almasının nedeni eğimin ters yönünde bir güncellemenin yapılmasının istenmesidir. Örneğin türev pozitif değer çıkmışsa hata değerinin düşmesi için negatif yönde bir güncellemenin yapılması istenir. $(r^t - y^t)$ beklenen değer ile çıktı arasındaki hata değeridir ve çıktı katmanı için girdi olan gizli katmandaki sinir hücresinin değeri z_h^t ile çarpılmasının nedeni ağırlıktaki değişimin girdi büyüklüğüne bağlı olmasıdır. Farklı değerlere sahip

girdiler için yapılan düzeltmenin büyüklüğü ile orantılı olması istenen bir durumdur. Böylece küçük bir girdi için gereksiz bir öğrenme süreci yaşanmamış olur (Alpaydın, 2004).

Birinci katmanın ağırlıklarının bulunmasında doğrudan en küçük kareler yöntemi kullanılamaz. Çünkü gizli katmanın sonucundaki hata terimi bilinmemektedir. Girdi ve gizli katman arasındaki birinci katman ağırlıklarının değişim miktarı aşağıdaki şekilde bulunur:

$$\begin{aligned}
 \Delta w_{hj} &= -\eta \frac{\partial E}{\partial w_{hj}} \\
 &= -\eta \sum_t \frac{\partial E^t}{\partial y^t} \frac{\partial y^t}{\partial z_h^t} \frac{\partial z_h^t}{\partial w_{hj}} \\
 &= -\eta \sum_t -(r^t - y^t) v_h z_h^t (1 - z_h^t) x_j^t \\
 &= \eta \sum_t (r^t - y^t) v_h z_h^t (1 - z_h^t) x_j^t
 \end{aligned} \tag{5.17}$$

Denklem (5.17)'deki $(r^t - y^t) v_h$ terimi gizli sinir hücresi h 'nin hata terimi olarak düşünülebilir. Bu hata gizli katmana doğru yayılarak gider. $(r^t - y^t)$ çıktının hatasıdır ve gizli sinir hücresinin ağırlığı olan v_h ile ağırlıklandırılır. $z_h^t(1 - z_h^t)$ ise sigmoid fonksiyonun türevidir ve x_j^t ise ağırlıklandırılmış toplamın w_{hj} 'ye göre türevidir (Alpaydın, 2004).

Başlangıç ağırlıklarının $[-0,01; 0,01]$ gibi küçük bir aralıkta seçilmesi sigmoid fonksiyonun türevinin alınabilir olması açısından önemlidir. Eğer büyük değerlerle başlanırsa sigmoid fonksiyonun türevi 0'a çok yakın olur ki bu da öğrenmenin olmaması anlamına gelir. Aynı zamanda girdi değerlerinin de 0 ile 1 arasında normalize edilmesi gerekmektedir. Farklı aralıklarda değerler alan girdilerin normalize edilerek aynı aralığa çekilmesi sağlanmış olur (Alpaydın, 2004).

Çıktı sayısının birden fazla olduğu durumda çıktı fonksiyonu:

$$y_i^t = \sum_{h=1}^H v_{ih} z_h^t + v_{i0} \tag{5.18}$$

ve hata fonksiyonu:

$$E = \frac{1}{2} \sum_t \sum_i (r_i^t - y_i^t)^2 \quad (5.19)$$

olarak yazılır. Toplu öğrenme kuralları uygulanarak ağırlıklardaki değişimler aşağıdaki şekilde bulunur:

$$\Delta v_{ih} = \eta \sum_t (r_i^t - y_i^t) z_h^t \quad (5.20)$$

$$\Delta w_{hj} = \eta \sum_t \left[\sum_i (r_i^t - y_i^t) v_{ih} \right] z_h^t (1 - z_h^t) x_j^t \quad (5.21)$$

GYA, gradyan inişi algoritma olduğu için birçok avantaja sahiptir. Basit bir algoritmadır. Fakat GYA yavaş yakınsayan bir algoritmadır. Bu problemi çözmek için momentum ve adapte edilen öğrenme oranı kullanılabilir. Momentum oranının temel mantığı bir önceki değişimin miktarının şimdiki değişime yansıtılmasıdır. Her hangi bir w_i ağırlığının momentum kullanıldığında gerçekleşen değişimi aşağıda gösterilmektedir:

$$\Delta w_i^t = -\eta \frac{\partial E^t}{\partial w_i} + \alpha \Delta w_i^{t-1} \quad (5.22)$$

α , momentum oranıdır ve genellikle 0,5 ile 1 arasında bir değer alınır. Bu yaklaşım çoğunlukla sürekli öğrenmede kullanılır. Öğrenme oranının küçük olması sonucun bulmasını çok yavaşlatır. Büyük olması ise yerel optimuma takılma riskini artırır. Momentum sabiti ağırlık değişimlerindeki yüksek değişim sıklıklarını kontrol etmek için formüle eklenebilir (Şahin, 2002).

Geri yayımlı algoritma basit ve popüler olmasına karşın çeşitli dezavantajlara sahiptir. Yavaş bir algoritmadır ve basit bir problemi çözmek için çok sayıda iterasyona ihtiyaç duyar. Ayrıca geri yayımlı algoritma, başlangıç ağırlıkları ile momentum oranı ve öğrenme oranına bağlıdır (Rooij ve diğ., 1996).

5.5. Yapay Sinir Ağı'nın Yapısının ve Parametrelerinin Belirlenmesi

Birçok çalışmada tek katmanlı yapay sinir ağı modelinin iyi sonuç verdiği ve yeterli olduğu görülmüştür. Ancak gizli katmandaki gizli sinir hücresi sayısı modelin iyi sonuç vermesi açısından önemlidir. Gizli sinir hücresi sayısı gerektiğinden az olursa öğrenme yeterli düzeyde gerçekleşemez. Gizli sinir hücresi sayısı fazla olursa da model öğrenemez ezberler ve test verisinin hatası büyük olur (Welstead, 1994).

GYA'nın en büyük dezavantajlarından birisi modelin iyi sonuçlara ulaşması için gizli sinir hücresi sayısının çok önemli olmasıdır (Şahin, 2002). Belirli bir problem için GYA'daki gizli sinir hücresini optimize eden artan/ azalan algoritmalar ve evrimsel algoritmalar olmak üzere iki yaklaşım mevcuttur (Castillo ve diğ., 2000):

Artan Algoritmalar: Algoritmanın temeli yeterli doğruluğa erişene kadar gizli sinir hücrelerinin modele eklenmesidir. Tek gizli sinir hücresi ile başlar ve hata değeri yeterince küçük olana kadar hücre eklemeye devam eder (Welstead, 1994). Bu algoritmanın en büyük problemi bir kere nöron eklemeye başladı mı azaltmanın mümkün olmaması ve çok büyük sinir ağları elde edebilmesidir. Ayrıca varolan nöronların ağırlıkları dondurulduklarından, bir nöron eklemek genellikle verimsiz olabilmekte ve çok sayıda nöron eklemek gerekebilmektedir (Castillo ve diğ., 2000).

Azalan Algoritmalar: Artan algoritmaların tersine azalan algoritmalar çok sayıda nöronla başlar ve nöronları teker teker eleyerek istenilen hata oranını elde edene kadar ağı küçültmeye devam eder (Welstead, 1994). Bu algoritmanın en büyük problemi de eğitimin yavaş olmasına sebep olan çok büyük ağlarla başlamasıdır. Fakat hangi nöronun eleneceğini belirleyen kritere bağlı olarak model başarılı sonuçlar verebilmektedir. Eğer elenecek nöronlar doğru belirlenirse iyi sonuçlar elde edilebilmektedir. Artan ve azalan algoritmaların her ikisi de gradyan inişi optimizasyon (gradient descent optimization) algoritmalarıdır, başka bir deyişle başlangıç noktasına göre yerel optimuma takılabilirler (Castillo ve diğ., 2000).

Evrimsel Algoritmalar: Çalışma kapsamında önerilen model anlatılırken evrimsel algoritmalarından genetik algoritmalar ile parametrelerin nasıl bulunduğu ayrıntılı olarak ilerleyen bölümlerde anlatılacaktır.

Eğitim sürecindeki maksimum iterasyon sayısının belirlenmesi de modelin veri grubunu ezberlemeyip öğrenmesi açısından önemlidir. İterasyon sayısı arttıkça eğitim veri grubunda hata giderek azalırken test veri grubunda hata belirli bir noktadan sonra artış gösterir. Test veri grubundaki hata artışı modelin veri grubunu ezberlemesi ile açıklanabilir (Şahin, 2002).

GYA rassal bir noktadan başlayan ve o noktadan hareketle optimum noktayı arayan bir gradyan inişi algoritmadır. Yerel optimum sayısı fazla olan karmaşık problemlerde yerel optimuma takılma olasılığı yüksektir. Bu sorunu gidermek için ortalama bir deneme sayısı belirlenir ve sinir ağı o sayı kadar tekrar tekrar çalıştırılır.

Böylece rassallıktan kaynaklanan yerel optimuma takılma problemi büyük ölçüde çözülmüş olur. Ancak ağın en iyi sonuca ulaşp ulaşmadığı asla kesin olarak söylenemez. Aynı zamanda bu tekrarlar modelin uzun sürmesine de yol açar. Yapay sinir ağının eğitimi başlangıç noktası ve öğrenme parametrelerinin çeşitli defalar değişimini gerektirir. Böylece yerel minimuma takılma riski de minimize edilmiş olur (Şahin, Ş.Ö., 2002).

5.6. Yapay Sinir Ağlarının Tahmin Modellerinde Kullanımı

YSA doğrusal olmayan sistemlerin modellenmesinde ve benzetiminde kullanılmaktadır. YSA'ların en çok kullanılan ve ilgi çeken alanlarından birisi de tahmin problemlerinde kullanımıdır (Azadeh ve diğ., 2006). Eldeki veri grubu ile herhangi bir varsayıma gerek duymadan karmaşık ve doğrusal olmayan ilişkileri modelleyebilen YSA ekonometrik tahmin modellerine göre daha avantajlıdır. AR (Autoregressive), MA (Moving Average), ARIMA (Auto Regressive Integrated Moving Average) ve diğer birçok tahmin modeli arasından veri grubunu en iyi tahmin edeni bulmak yerine YSA'ya veri grubu beslenir ve genellikle oldukça iyi sonuçlar veren modeli bulması ve sonuçları ortaya koyması beklenir (Şahin, 2002).

YSA tahmin modellerinde kullanılırken genel olarak aşağıdaki adımları izler (Şahin, 2002):

- *Tahmini yapılacak olan konunun belirlenmesi:* Tahmin edilecek konu ve hangi faktörlerin tahmin edilecek konuyu etkileyeceğinin belirlenmesi gerekmektedir.
- *İlgili verilerin derlenmesi ve YSA'da kullanılmak üzere normalize edilmesi:* Tahmin edilen konu ve kapsamı belirlendikten sonra ilgili değişkenlerin verileri toplanır ve YSA'ya girdi olacak şekilde normalize edilir. Normalizasyondaki amaç tüm değişkenleri aynı aralıkta ifade edebilmektir (Alpaydın, 2004).
- *Verilerin eğitim, gerçekleştirme ve test grupları olarak ayrılması:* Eğitim verisi ağın eğitimi için, gerçekleştirme verisi modelin karmaşıklığının belirlenmesi için, test verisi de modelin performansının test edilmesi için kullanılır (Alpaydın, 2004).
- *Uygun yapay sinir ağı yapısının belirlenmesi:* Gizli düzey sayısı, gizli sinir hücresi sayısı, hücrelerde kullanılacak olan hareket fonksiyonu gibi ağın özellikleri belirlenmelidir. Bölüm 5.5'te anlatılan yöntemlerle ağın yapısı belirlenebilir.

- *Uygun öğrenme algoritmasının seçilmesi:* Problemin tipine göre hangi öğrenme algoritmasının seçileceğine karar verilmelidir.
- *YSA'nın eğitilmesi:* Eğitim veri grubu kullanılarak ağın eğitimi gerçekleşir. Gerçekleme verisi ile bulunan hata değeri ile modelin yapısına karar verilir.
- *YSA'nın test edilmesi:* YSA test edildikten ve yapısına karar verildikten sonra, test verisi ile model test edilir.
- *YSA'nın tahmin için kullanılması:* Hedeflenen bilgilerin YSA kullanılarak tahmini gerçekleştirilir.

Eğitilen yapay sinir ağının test edilmesi aşamasında bir performans ölçütünün kullanılması gerekir. Tahmin modellerinde en sık kullanılan ölçüt hataların karesinin ortalamasıdır (MSE). MSE aşağıdaki şekilde bulunur:

$$MSE = \frac{1}{n} \sum_k (r_k - y_k)^2 \quad (5.23)$$

y_k , k çıktısının gerçek değeri iken r_k k çıktısının tahmin değeri, n ise örnek sayısıdır. YSA'da bir başka sık kullanılan performans ölçütü ise hata karelerinin ortalamasının kareköküdür (RMSE).

$$RMSE = \sqrt{\frac{1}{n} \sum_k (r_k - y_k)^2} \quad (5.24)$$

Yapay sinir ağı uygulamasında en sık kullanılan performans ölçütlerinden birisi olan RMSE farklı uygulamaların YSA ile elde edilen sonuçlarında bir karşılaştırma yapmak için sağlıklı sonuçlar vermeyebilir. Bunun nedeni tahmin edilen değişkenlerin birimlerinin farklı olmasıdır. Örneğin, milyonlarla ifade edilen bir değişkenin tahminini sonucunda çıkan yüz birimlik bir hata ile binlerle ifade edilen bir değişkenin tahmini sonucu çıkan yüz birimlik hata aynı performans düzeyini ifade etmez. Bu yüzden RMSE değeri yerine bir başka performans ölçütü olan göreceli hata (RE) değeri kullanılabilir. RE değeri birimsiz olduğu için iki YSA'nın performans karşılaştırmasında kullanılabilir (Şahin, 2002):

$$RE = \sqrt{\frac{\sum_k (r_k - y_k)^2}{\sum_k r_k^2}} \quad (5.25)$$

6. GENETİK ALGORİTMALAR


6.1. Genetik Algoritmalarla İlgili Temel Kavramlar

Genetik algoritmalar (GA) doğal seçim ve genetikten esinlenen bir arama ve optimizasyon tekniğidir (Herrera ve Verdagay, 1996). GA’da kullanılan temel kavramlardan aşağıda bahsedilmektedir:

Gen: Kendi başına anlamlı genetik bilgi taşıyan en küçük birimdir (Gen ve Cheng, 1997).

Kromozom (Birey): Genlerin birleşiminden oluşur. Genetik algortmada her kromozom alternatif bir çözümü verir (Gen ve Cheng, 1997).

Popülasyon (Nesil): Kromozomların (bireylerin) biraraya gelmesi ile popülasyonlar oluşur. Belirli bir problemde popülasyondaki birey sayısı sabittir (Biroğul, 2005). Problemin yapısına bağlı olarak popülasyon büyüklüğü 10 ile 100 arasında belirlenebilir. Popülasyon, uygun alternatif çözümler kümesidir (Engin, 2001)



Şekil 6.1: Gen, kromozom ve popülasyon örnek gösterimi

Evrım: Bir popülasyon üzerinde genetik işlemlerin gerçekleşmesi sürecidir (Engin, 2001).

Seçim: Mevcut popülasyondan gelecek popülasyona aktarılacak olan kromozomların seçilme işlemidir (Biroğul, 2005).

Mutasyon: Bireyin bir veya daha fazla geninin değişim geçirerek başka bir birey haline gelmesidir. Mutasyon sonucu yeni bireyler oluşur (Deb, 2001).


Çaprazlama: Popülasyondan seçilen iki bireyin kromozomlarının bir bölümünün yer değiştirmesi ile iki yeni bireyin oluşmasıdır. Çaprazlama sonucu yeni bireyler oluşur (Deb, 2001).

Uygunluk Fonksiyonu: Problemin amaç fonksiyonudur. Kromozomların çözümde gösterdikleri başarıyı gösteren uygunluk değeri kromozomun hedefe ne kadar yaklaştığının ölçüsüdür. Bir başka deyişle uygunluk değeri kromozomun çözüm kalitesini gösterir (Engin, 2001). Hangi bireylerin gelecek nesile aktarılacağı bireylerin uygunluk değerlerine göre belirlenir (Biroğul, 2005).

6.2. Genetik Algoritmaların Temel Çalışma Prensipleri

GA rassal arama teknikleri kullanarak çözüm bulmaya çalışan ve parametre kodlama esasına dayanan bir arama tekniğidir. GA’da çeşitli genetik işlemler sonucunda popülasyonun evrilmesi Darwin’in “güçlü olanın hayatta kalması (survival of the fittest)” prensibine dayanır (Herrera ve Verdegay, 1996). Genetik algoritma tekniği, Michigan Üniversitesinde John Holland, çalışma arkadaşları ve öğrencileri tarafından 1970’li yıllarda geliştirilmiştir. Araştırmalarının amacı doğal sistemlerin öğrenme süreçlerini açıklamak ve bu süreçleri bilgisayar ortamına taşıyarak yapay sistemler tasarlamaktır (Goldberg, 1989). Daha sonra Goldberg’in (1989) GA’lar üzerine yazdığı kitap bu konu için bir yapıtaşını oluşturmuştur.

GA popülasyon adı verilen rassal bir başlangıç çözüm kümesinden yola çıkmasıyla geleneksel arama tekniklerinden ayrılır. Popülasyondaki her birey kromozom olarak adlandırılır ve her bir kromozom ele alınan problemin uygun bir çözümüdür. Her kromozom bir dizi genlerden oluşur. Kromozomlar her nesilde evrilir, gelişirler. Nesilden nesile kromozomlar uygunluk değerlerini kullanarak gelişirler. Yeni bir nesil oluşturmak için çocuk (offspring) adı verilen bireyler meydana getirilir. Yeni bireyler de varolan nesilden seçilen iki ebeveynin çaprazlama operatörü ile eşleştirilmesi veya mutasyon operatörü ile seçilen bir bireyin kromozomunun değiştirilmesi ile oluşur. Yeni popülasyon çocuklar ve ebeveynler arasındaki en



Şekil 6.2: Genetik Algoritmanın genel işleyişi

güçlü (uygun) bireylerin seçilmesi, diğerlerinin popülasyondan çıkartılmasıyla oluşur. Daha güçlü kromozomların yaşamak için daha fazla şansları vardır. Birçok nesilden sonra popülasyon optimum veya lokal optimum olduğu düşünülen en iyi kromozoma doğru yakınsar (Gen ve Cheng, 1997).

Şekil 6.2’de GA’nın temel çalışma mantığını gösteren bir akış diyagramı görülmektedir. Algoritma bireyin kodlanması ile başlar. Daha sonra bireyin çözüm kalitesini verecek olan uygunluk fonksiyonu belirlenir. Popülasyonundaki kromozom sayısı belirlenir. Belirlenen popülasyon büyüklüğü kadar rassal bireyler oluşturulur, böylece başlangıç popülasyonunu hazırlanır.

Algoritmanın sonlandırma kriteri belirlenir. Algoritma tüm bireyler aynı gen yapısına ulaştığında ya da belirlenen bir popülasyon sayısına ulaşıldığında son bulur. Durdurma kriterine karar verildikten sonra uygunluk fonksiyonu kullanılarak her birey için uygunluk değeri hesaplanır. Artık algoritma evrim için hazırdır. Bir başka deyişle bundan sonra popülasyondaki bireylere genetik işlemler uygulanır ve popülasyonun evrimi sağlanır.

Popülasyondaki bireylerin uygunluk değerlerine göre seçim işlemi yapılır. En büyük uygunluk değerine sahip olan bireyin seçilme olasılığı da diğer bireylerin seçilme olasılığından daha büyüktür. Daha sonra seçilen bireylere çaprazlama ve mutasyon operatörleri uygulanır. Bireyin çaprazlama veya mutasyona uğrayacağı çaprazlama ve mutasyon olasılığına bağlıdır.

Çaprazlama ve mutasyon işlemlerinden sonra eski popülasyon ve oluşan yeni popülasyondan en güçlü, yani uygunluk değeri optimuma en yakın olan bireyler yeni popülasyonu oluşturur. Eğer durdurma kriteri sağlanıyorsa algoritma sonlanır. Eğer durdurma kriteri sağlanmıyorsa, sağlanana dek oluşan yeni popülasyona seçim, mutasyon ve çaprazlama operatörleri uygulanır ve yeni popülasyonlar oluşturulur. Durdurma kriteri sağlandığında bulunan kromozom oluşan popülasyonlarda en iyi sonucu veren kromozomdur, ancak global optimum olmayabilir.

6.3. Genetik Algoritmaların Geleneksel Yaklaşımlardan Farkı

GA birçok konuda geleneksel optimizasyon ve arama tekniklerinden farklılık gösterir (Goldberg, 1989). Geleneksel yaklaşımlar tek noktadan hareket edip global optimuma yakınsamaya çalışırlar. Bunu yaparken de komşu noktalara bakıp en

uygun yönde ilerleyerek optimuma ulaşırlar. Ancak lokal optimuma takılma olasılıkları fazladır. Eğer problemin tüm lokal optimumlarının global optimuma eşit olduğunu garanti eden bir konveks yapısı varsa global optimumu geleneksel yaklaşım kesin olarak bulabilir. GA ise noktalar kümesinde arama yaptığı için global optimumu bulma olasılığı geleneksel yaklaşımlara göre fazladır (Gen ve Cheng, 1997).

GA optimizasyon problemi ile ilgili matematiksel bilgiye ihtiyaç duymazlar. Tek ihtiyacı olan uygunluk fonksiyonudur. GA, evrimsel doğasından dolayı problemle ilgili ön bir matematiksel çalışma gerektirmez. Kesikli, sürekli veya karışık uzay alanlarında tanımlı amaç fonksiyonu ve kısıtları olan problemleri de ele alabilir (Gen ve Cheng, 1997).

Goldberg (1989) geleneksel yaklaşımlar ile genetik algoritmaların farklarını şu şekilde özetlemiştir:

- ◆ GA çözümlerin kendileri ile değil çözüm kümelerinin kodlanmış halleriyle çalışır.
- ◆ GA tek noktada değil noktalar topluluğunda (popülasyonlar) arama yapar.
- ◆ GA sadece uygunluk fonksiyonu kullanır, türev ya da benzeri işlemlere ihtiyaç duymaz.
- ◆ GA deterministik kuralları değil stokastik geçiş kurallarını kullanır.

6.4. Genetik Algoritmaların Temel Bileşenleri

6.4.1. Genetik Kodlama

Problemin çözümünün bir kromozoma nasıl kodlanacağı GA için temel problemlerden biridir. Holland'ın çalışmasında ikili kodlama kullanılmıştır (Gen, Cheng, 1997). İkili kodlama çözüm uzayındaki değerlerin ikilik sayma sistemine (0, 1) dönüştürülmesiyle gerçekleşir (Goldberg, 1989). Birçok GA uygulamasında, özellikle endüstri mühendisliği uygulamalarında, ikili kod sisteminin doğal bir kodlama olmamasından kaynaklanan sorunlar ortaya çıkmıştır. Son yıllarda çeşitli problemlere özel kodlama teknikleri geliştirilmiştir. Örneğin kısıtlı optimizasyon problemlerinde gerçek değerli kodlama uygulanırken, kombinatoriyal optimizasyon

problemlerinde tamsayı kodlamanın uygulandığı görülmektedir. Uygulamalarda dikkat edilmesi gereken en önemli konulardan biri kodlamanın anlamlı ve problemlerin yapısına uygun olmasıdır (Gen, Cheng, 1997).

6.4.2. Uygunluk Fonksiyonu

Amaç fonksiyonu genetik algoritmada uygunluk fonksiyonudur. Uygunluk fonksiyonu maksimize etmek istediğimiz kar ya da fayda olarak düşünülebilir (Goldberg, 1989). GA ile problem arasındaki temel bağlantı uygunluk fonksiyonu ile sağlanır (Man ve diğ., 1999). Populasyondaki her birey için uygunluk değeri hesaplanır. Algoritma durdurma kriteri eğer hedeflenen bir uygunluk değeri ise herhangi bir bireyin uygunluk değeri hedef değere ulaştığında algoritma durur. Durdurma kriteri olarak populasyon sayısı da verilebilir. Bu durumda da algoritma belirlenen populasyon sayısına ulaştığında son bulur. Eğer amaç minimizasyonsa son populasyonda uygunluk değeri minimum olan bireyi optimum çözüm olarak alır. Eğer amaç maksimizasyonsa uygunluk değeri maksimum olan bireyi alır (Rooij, 1996).

6.4.3. Başlangıç Popülasyonu Oluşturma

Başlangıç popülasyonunu rassal değerli genlerden oluşan kromozomlar meydana getirir. Eğer kromozom ikili kodlama ile kodlanıyorsa başlangıç popülasyonundaki kromozomların her geni eşit şansa 0 veya 1 değerini alır. Eğer gerçek değerli kodlanıyorsa belirli bir aralıkta düzgün veya normal dağılım gibi çeşitli dağılımlar kullanılarak başlangıç popülasyonu oluşturulur (Rooij ve diğ., 1996).

Belirlenmesi gereken diğer bir parametre de popülasyonun büyüklüğüdür. Bir başka deyişle bir nesli oluşturan kromozom sayısının da belirlenmesi gerekir. Popülasyon büyüklüğünün belirli bir optimal değeri yoktur ancak küçük popülasyonlar (50 kromozomdan daha az) büyük popülasyonlara (50 kromozomdan daha fazla) göre daha kısa zamanda çözüme yakınsar. Yakınsamadan kastedilen popülasyondaki tüm kromozomların aynı genleri taşıdığı durumdur. Böylece gelecek nesiller de aynı genlere sahip olurlar. İdeal durumlarda algoritma global optimuma yakınsar ancak küçük popülasyonların lokal optimumlara yakınsaması söz konusu olabilir. Popülasyon büyüklüğünü belirlerken yakınsama süresi ve global optimuma yakınsama olasılığı arasında bir denge noktasının sağlanması gerekir (Rooij ve diğ., 1996).

6.4.4. Genetik Operatörler

Genetik algoritma seçim, çaprazlama ve mutasyon olmak üzere temelde 3 operatörden oluşmaktadır (Goldberg, 1989):


◆ Seçim:

Seçim, bireylerin uygunluk fonksiyonu değerlerine göre kopyalanması işlemidir. Bireylerin uygunluk fonksiyonuna göre kopyalanması uygunluk fonksiyon değeri yüksek olan bireyin yaşama şansının da yüksek olması anlamına gelmektedir. Bu operatör Darwin'in doğal seleksiyon teorisinin yapay bir modelidir (Goldberg, 1989).

Seçim operatörü çeşitli şekillerde uygulanabilir. En yaygın uygulanma şekli rulet çemberi yöntemidir. Bu yöntemde bir rulet yaratılır ve her birey uygunluk fonksiyonu değerine göre rulet tekerinde pay sahibi olur. Bu durumda uygunluk değeri büyük olan bireyin rulet tekerindeki payı da büyük olur. Rassal bir sayı atıldığında uygunluk değeri bireyin seçilme şansını belirler (Goldberg, 1989).

◆ Çaprazlama:

Seçim sonrasında yapılan çaprazlama iki adımda gerçekleşir. İlk adımda seçilen yeni bireyler rassal olarak eşleştirilir. İkinci adımda da çaprazlama gerçekleşir (Goldberg, 1989). Eşleşen iki kromozomun özellikleri biraraya getirilerek yeni birey oluşur. En basit çaprazlama rassal bir kesim noktasının seçildiği ve bu noktadan itibaren iki ebeveynin kromozomlarının yer değiştirdiği çaprazlama yöntemidir (Şekil 6.3). Genetik Algoritmanın iyi bir performans göstermesi büyük ölçüde çaprazlama operatörünün performansına bağlıdır (Gen ve Cheng, 1997).



Şekil 6.3: Basit çaprazlama operatörü

Çaprazlama olasılığı her nesilde üretilen çocuk sayısının popülasyon büyüklüğüne oranıdır. Bu oran her nesilde çaprazlamaya uğrayacak olan birey sayısını belirler. Yüksek çaprazlama oranı çözüm uzayında daha büyük bir alanın aranmasını sağlar

ve yerel optimuma takılmayı önler. Eğer oran çok yüksek olursa çok fazla arama yapması gerekeceğinden vakit kaybına neden olur (Gen ve Cheng, 1997).

◆ ***Mutasyon:***

Mutasyon operatörü kromozomların bir veya daha fazla geninde rassal değişimler meydana getirir. Çaprazlama ve seçim sonrasında uygunluk değeri yüksek bireyler oluşsa bile seçim ve çaprazlama sonrasında popülasyondaki bazı genlerin kaybı söz konusu olabilir (Goldberg, 1989). GA’da mutasyon iki önemli noktada öneme sahiptir: (1) seçim sırasında kaybedilen genlerin tekrar popülasyona katılmasını sağlayabilir; (2) başlangıç popülasyonunda yer alamayan genlerin popülasyona katılmasını sağlayabilir (Gen ve Cheng, 1997).

Mutasyon olasılığı bir genin mutasyona uğrama olasılığıdır. Başka bir deyişle mutasyon olasılığı, her denemede kaç yeni genin popülasyona gireceğini belirler. Mutasyon olasılığı çok düşük olduğunda uygunluk değerini arttıracak pek çok gen popülasyona giremeyebilir. Çok yüksek olduğunda ise rassallık her popülasyonda çok yüksek olacağından popülasyonların gücünü gelecek nesillere aktaramayabilir, böylece algoritma geçmiş aramalardan öğrenme gücünü kaybeder (Gen ve Cheng, 1997).

6.5. Genetik Algoritmaların Kullanım Alanları

Optimizasyon problemleri mevcut durumu tek bir amaç fonksiyonuna göre değerlendirir. GA’da amaç fonksiyonu uygunluk fonksiyonudur. Birden fazla amaç fonksiyonunun olduğu durumlarda ise hepsini bir amaç fonksiyonunda toplamak zordur. Bu durumda çok amaçlı problemler ortaya çıkar (Goldberg, 1989). Tasarım, planlama, ulaşım ve bütçeleme problemleri çok amaçlı problemlerin kullanım alanlarına örnek olarak verilebilir (Engin, 2001).

GA bir çözüm kümesinden (popülasyon) diğer bir çözüm kümesine arama yaparak ilerlediğinden matematiksel bir bilgiye ihtiyaç duymaz. GA meta sezgisel bir metot olması nedeniyle birbirinden farklı çok amaçlı optimizasyon problemlerinde kullanılabilir (Engin, 2001).

GA kombinatoriyal optimizasyon, güvenilirlik (reliability) optimizasyonu, çizelgeleme, ulaşım, tesis yeri tasarımı problemleri gibi endüstri mühendisliğinin temel konularında uygulanmakta ve başarılı sonuçlar elde etmektedir (Gen ve Cheng,

1997). Genetik Algoritmaların, pek çok alanda olduğu gibi sinir ağlarının optimizasyonunda da başarılı oldukları görülmektedir (Rooij ve diğ., 1996). Çalışmanın ilerleyen bölümlerinde GA'nın YSA'nın optimizasyonunda kullanım şekilleri detaylı anlatılacak ve yapılan uygulamalardan bahsedilecektir.

7. ÖNERİLEN MODEL

7.1. Genetik Algoritmalar ile Yapay Sinir Ağlarının Birarada Kullanılması

GA ve YSA, dinamik yapıları ve karmaşık problemlerin çözümünde gösterdikleri başarı nedeniyle bilgisayar bilimcileri ve mühendisler tarafından ilgi çekici bulunan iki konudur. Her iki yaklaşım da doğal süreçlerin bilgisayar ortamına aktarılmasına dayansa da zaman açısından farklılıklar gösterir. Evrimsel süreçler nesiller boyunca ilerlediğinden uzun bir sürede etkisini göstermekteyken, sinir sistemleri kısa süreli periyotlarda etkisini göstermektedir (Schaffer ve diğ., 1992).

YSA'nın eğitiminde kullanılan GYA bir çok alanda başarıyla uygulansa da pratikte şu sorunlarla karşılaşabilmektedir: (1) modelin yakınsaması çok yavaş ve başlangıç ağırlık değerlerine bağımlıdır; (2) global optimuma yakınsaması garanti değildir ve (3) öğrenme parametrelerinin ve gizli katman sayısının sezgisel olarak veya sistematik testlerle bulunması gerekmektedir. Yakınsama problemi gradyan takip (gradient following) tekniklerin kullanımı ile aşılabılır, ancak değişen öğrenme parametreleri ve ağ büyüklüğü problemin yapısına bağlı olarak değiştiği için (2) ve (3) baş edilmesi güç problemlerdir (Castillo ve diğ., 2000).

GA ve YSA yukarıdaki sorunları çözmek için çeşitli şekillerde biraraya gelebilirler. GYA'nın GA ile birlikte kullanımı iki algoritmanın da olumlu yönlerini birleştirmek içindir. GA global optimumu bulma yeteneğine sahip bir algoritmadır. GYA ise GA'nın bulduğu optimum çözümden yola çıkarak en yakın yerel optimumu başarı ile bulabilen bir algoritmadır (Castillo ve diğ., 2000). Araştırmacılar bu iki modelin bir arada kullanımının problemlerin çözümünde bir sinerji yaratacağını düşünmektedirler (Schaffer ve diğ., 1992). Tablo 7.1'de GA'nın YSA'da kullanıldığı çalışmalar özetlenmiştir.

Tablo 7.1: GA ile YSA'nın birarada kullanıldığı çalışmalar

TARİH	ÇALIŞMANIN YAZARLARI	GA'NIN YSA'DAKİ KULLANIMI	KULLANILAN ALAN	SONUÇ
2007	Wang ve Huang	Öğrenme parametreleri, başlangıç ağırlık faktörü, gizli katman ve gizli sinir hücresi sayısı GA ile bulunuyor.	Kaotik zaman serileri	Önerilen model GA ile eğitilen GYA'dan daha iyi sonuç vermektedir.
2007	Yi-Hui	Gizli katmandaki sinir hücresi sayısı ve öğrenme parametreleri GA ile bulunuyor.	Onarılabilir sistemlerin (mekanik, elektronik, iletişim araçları vs) güvenilirliğinin tahmini	Önerilen model ARIMA ve yalın YSA'dan daha iyi sonuç vermektedir.
2006	Doganis ve diğ.	Girdilerin belirlenmesinde GA kullanılıyor.	Raf ömrü kısa olan gıdaların satış tahmini	Önerilen model doğrusal ve doğrusal olmayan modellerin kombinasyonu olan tahmin modellerine göre daha iyi sonuç vermektedir.
2005	Ferentinos	Minimizasyon algoritması, gizli katman ve gizli sinir hücresi sayısı ve aktivasyon fonksiyonu GA ile bulunuyor.	Bioloji mühendisliği (biological engineering) uygulamaları	Önerilen model klasik GYA'dan daha iyi sonuç vermektedir.
2005	Vlahogianni ve diğ.	GA ile parametrelerin optimize edildiği 3 farklı model uygulanıyor.	Trafik akış tahmini	Tek değişkenli zaman serisinde 3 modelin de ARIMA'ya göre daha iyi sonuç verdiği görülüyor.
2005	Kim ve Bae	Gizli katmandaki sinir hücresi sayısı, bipolar sigmoid fonksiyonun gradyanı, lineer fonksiyonun gradyanı, başlangıç ağırlıklarının dağılımı ve öğrenme toleransı GA ile bulunuyor.	Bilgisayar modelleri (plasma process)	Klasik GYA'dan daha iyi sonuç vermektedir.
2004	Fish ve diğ.	YSA'yı eğitmek için GA kullanılıyor.	Müşteri tercihleri ve marka payının (brand share) modellenmesi	Klasik GYA'dan daha iyi sonuç vermektedir.

Tablo 7.1: (devamı)

TARİH	ÇALIŞMANIN YAZARLARI	GA'NIN YSA'DAKİ KULLANIMI	KULLANILAN ALAN	SONUÇ
2004	Niska ve diğ.	Gizli katman sayısı, gizli katmandaki nöron sayısı ve girdiler GA ile bulunuyor.	Hava kirliliği tahmini	Klasik GYA'dan daha iyi sonuç vermektedir.
2004	Sexton ve diğ.	Ağa girilen gereksiz girdilerin belirlenmesinde GA kullanılıyor.	Kaotik zaman serileri	Önerilen model GA ve klasik GYA ile eğitilen YSA'ya göre daha iyi sonuç vermektedir.
2001	Kuo	Başlangıç ağırlıkları GA ile bulunuyor. Bulanık YSA kullanılıyor.	Satış tahmini	ARMA ve GYA'dan daha iyi sonuç vermektedir.
2000	Castillo ve diğ.	Başlangıç ağırlıkları ve gizli katmandaki sinir hücre sayısı GA ile bulunuyor.	Sınıflandırma (kanser teşhisi)	Önerilen model GYA'nın farklı versiyonlarından daha iyi sonuç vermektedir.
2000	Sexton ve Gupta	YSA'yı eğitmek için GA kullanılıyor.	Kaotik zaman serileri	Klasik GYA'dan daha iyi sonuç vermektedir.
1999	Gupta ve Sexton	YSA'yı eğitmek için GA kullanılıyor.	Kaotik zaman serileri	Klasik GYA'dan daha iyi sonuç vermektedir.
1999	Sexton ve diğ.	YSA'yı eğitmek için GA ve Tavlama Benzetimi teknikleri kullanılıyor.	Zaman serileri ve sınıflandırma	GA, Tavlama Benzetiminden ve klasik GYA'dan daha iyi sonuç vermektedir.
1995	Porto ve diğ.	YSA'nın eğitiminde kullanılan GA, Tavlama Benzetimi ve GYA tekniklerini karşılaştırıyor.	Sınıflandırma	GA ve Tavlama Benzetimi, GYA'dan daha iyi sonuç vermektedir.

Tablo 7.1 incelendiğinde GA'nın kullanımına göre çalışmalar 3 grupta incelenebilir:

- ◆ Optimum ağırlıkların belirlenmesi (Ağın eğitilmesi)
- ◆ Optimum parametrelerin ve sinir ağı yapısının belirlenmesi
- ◆ Girdilerin belirlenmesi

7.1.1. Optimum Ağırlıkların Belirlenmesi

Optimum ağırlıkların belirlenmesi ağın eğitiminin genetik algoritma ile yapılması anlamına gelmektedir. GYA gibi gradyan bazlı arama teknikleri YSA'nın eğitilmesinde en yaygın kullanılan optimizasyon teknikleri olmasına rağmen, araştırmalar göstermiştir ki gradyan teknikler global optimumun bulunmasında sınırlı kalmıştır (Fish ve diğ., 2004; Sexton ve diğ., 1999-2000; Gupta ve Sexton, 1999; Porto ve diğ., 1995).

Global arama teknikleri bu sorunu çözmek için potansiyel bir çözüm olarak tanımlanmaktadır. Literatürde YSA'nın eğitiminde kullanılan global arama teknikleri genellikle genetik algoritmalar, tabu arama (tabu search) ve tavlama benzetimi (simulated annealing) teknikleridir (Sexton ve diğ., 1999-2000; Porto ve diğ., 1995).

Porto ve diğ. (1995) sınıflandırma problemine GA, tavlama benzetimi ve GYA teknikleri ile eğitilen üç YSA modelini uygulamışlar ve sonuçlarını karşılaştırmışlardır. Ağın eğitiminde global arama tekniklerinden GA ve tavlama benzetimi, GYA'dan daha iyi sonuç vermiştir.

Sexton ve diğ. (1999) ise YSA'nın tahmin ve sınıflandırma problemleri için eğitiminde GA ve tavlama benzetimi tekniklerini karşılaştırmışlardır. GA, tavlama benzetimine göre daha iyi sonuç vermiştir. Porto ve diğ.'nin (1995) elde ettiği sonuçlara benzer şekilde GA ve tavlama benzetiminin her ikisi de GYA'dan daha iyi sonuç vermiştir.

Gupta ve Sexton (1999-2000) kaotik zaman serilerinin tahmininde, Fish ve diğ. (2004) müşteri tercihleri ve marka payının (brand share) modellenmesinde GA ile eğitilmiş YSA modeli önermişlerdir. Her iki çalışmada da GA'nın, GYA'ya göre daha başarılı bir eğitim algoritması olduğu görülmüştür. GA'nın bir nokta kümesinden diğer bir nokta kümesine hareket eden arama süreci yerel optimuma takılma olasılığını azaltmaktadır. GA aynı zamanda karmaşık matematiksel hesaplamalara gerek duymayan etkin bir yöntemdir (Sexton ve diğ., 1999-2000;

Porto ve diğ., 1995, Rooij ve diğ., 1996). Teorik analizler GA'nın büyük ve kompleks arama uzaylarında yüksek performans gösterdiklerini doğrulamaktadırlar (Schaffer ve diğ., 1992).

Ağın eğitiminde kullanılan GA'nın GYA'ya göre avantajları şu şekilde özetlenebilir (Rooij ve diğ., 1996; Schaffer ve diğ., 1992):

- (1) GA hata gradyanı bilgisine ihtiyaç duymaz.
- (2) GA transfer fonksiyonlarının türevi alınmadığı durumlarda kullanılır.
- (3) GA'nın yerel optimuma takılma olasılığı GYA'ya göre daha düşüktür.

GA'nın dezavantajı ise GYA'ya göre daha yavaş bir algoritma olmasıdır (Rooij ve diğ., 1996).

7.1.2. Optimum parametrelerin ve sinir ağı yapısının belirlenmesi

GYA tahmin problemlerinde pek çok avantaj sağlasa da yerel optimuma takılma olasılığının yüksek olması gibi bir dezavantaja sahiptir. Bu sorun da GYA'nın farklı uygulamalarda iyi bir tahmin edici olmasını engellemektedir. Tahminin performansını artırmak için GYA'yı optimize edecek etkili bir teknik gereklidir (Wang ve Huang, 2007).

Birçok çalışma GA ile optimize edilen GYA ile klasik GYA (sadece gradyan arama tekniği kullanan GYA)'nın performansını karşılaştırmaktadır. Tablo 7.1'de GA ile parametreleri ve ağ yapısı optimize edilen çalışmalar ve sonuçlar görülmektedir. Sonuçlar göstermektedir ki GA ile optimize edilen GYA klasik GYA'ya göre daha iyi sonuç vermektedir. Klasik GYA'da parametreler duyarlılık analizindeki sırayla değiştirilerek her seferinde ağ tekrar çalıştırılır. Bu şekilde uygun parametreler belirlenmeye çalışılır. Castillo ve diğ. (2000) bir sınıflandırma probleminde GYA'nın başlangıç ağırlıklarının ve gizli katmandaki sinir hücresi sayısını GA ile bulmuşlar ve klasik GYA'ya göre daha iyi sonuç verdiğini görmüşlerdir. Benzer şekilde Kuo (2001) satış tahmini probleminde başlangıç ağırlıklarının GA ile optimize edildiği bir bulanık ağ modeli önermiş ve klasik bir istatistiksel teknik olan ARMA ve klasik GYA'dan daha iyi sonuç vermiştir.

Tablo 7.1 incelendiğinde sinir ağının yapısının optimizasyonunda genel olarak gizli katman sayısı ve gizli katmanlardaki nöron sayısı GA ile belirlenir. Birçok çalışmada YSA'nın yapısını oluştururken tek gizli katmanın yeterli olduğu görülmüştür (Sexton

ve diğ., 1999-2000). Sinir ağının yapısının yanında başlangıç ağırlıkları ve öğrenme parametreleri de GA ile belirlenebilir. Başlangıç ağırlıklarının dinamik olarak değişmesi GYA' nın yerel optimuma takılmasını önleyecektir (Wang ve Huang, 2007; Kuo, 2001; Castillo ve diğ., 2000).

Benzer şekilde minimizasyon algoritmasının (steepest descent vs) ve hareket fonksiyonunun da GA ile belirlendiği çalışmalar bulunmaktadır (Ferentinos, 2005). Kim ve Bae (2005) gizli katmandaki sinir hücresi sayısı, başlangıç ağırlıklarının dağılımı ve öğrenme toleransının yanında bipolar sigmoid fonksiyonun gradyanı ve lineer fonksiyonun gradyanını da GA ile bulmuşlardır ve GA, klasik GYA ile karşılaştırıldığında daha iyi sonuç vermiştir.

Vlahogianni ve diğ. (2005) trafik akışının tahmininde 3 farklı model uygulamışlardır. İlk modelde ağ klasik GYA ile eğitilmiş ve öğrenme oranı (η), momentum ve gizli sinir hücresi sayısı (h) GA ile bulunmuştur. İkinci modelde ağ öğrenme oranı adapte edilen klasik GYA ile eğitilmiş ve h GA ile bulunmuştur. Son olarak üçüncü modelde ise ağ ölçekli bileşik gradyan inişi (scaled conjugate gradient descent) ile eğitilmiş ve h GA ile bulunmuştur. Tek değişkenli ve çok değişkenli zaman serileri için 3 model de ayrı ayrı uygulanmış ve tek değişkenli zaman serisinde üç modelin de ARIMA'ya göre daha iyi sonuç verdiği görülmüştür. Ancak daha kısa sürede eğitildiği ve optimize edilmesi daha kolay olduğundan ilk model tercih edilmiştir.

Ferentinos (2005) biyoloji alanında bir YSA modeli önermiştir. Önerdiği sinir ağının minimizasyon algoritmasını (steepest descent, quasi-Newton, Levenberg-Marquardt, Conjugate gradient algorithms), gizli katman ve gizli sinir hücresi sayısını ve aktivasyon fonksiyonunu (lojistik, tanh, doğrusal) GA ile bulmuştur. Önerilen model parametreleri deneme yanılma yoluyla bulunan klasik GYA'dan daha iyi sonuç vermiştir.

Yi-Hui (2007) onarılabilir sistemlerin (mekanik, elektronik, iletişim araçları vs) güvenilirliğinin tahmini için gizli katmandaki sinir hücresi sayısının ve öğrenme parametrelerinin GA ile belirlendiği bir sinir ağı modeli önermişlerdir. Önerilen model ARIMA ve yalın YSA'dan daha iyi sonuç vermiştir.

Son olarak Wang ve Huang kaotik zaman serilerinin tahmininde iki yapay sinir ağı modelini karşılaştırmışlardır. Bu yapay sinir ağı modellerinin ilkinde GYA'nın öğrenme oranı, moment faktörü, başlangıç ağırlık faktörü, gizli katman ve gizli sinir

hücresi sayısı GA ile bulunmuştur. İkinci model ise Sexton ve Gupta (2000) nın önerdiği, ağın eğitiminde GYA yerine GA'nın kullanıldığı modeldir. Bir başka deyişle çalışma kapsamında GA'nın YSA modellerindeki iki kullanım alanı karşılaştırılmıştır. Çalışma sonucunda GYA'nın parametrelerini GA ile optimize eden ilk sinir ağı modelinin daha iyi sonuç verdiği görülmüştür (2007).

Parametrelerin GA ile optimize edildiği tüm çalışmalara baktığımızda klasik GYA'dan ya da klasik istatistiksel tekniklerden (ARIMA vb) daha iyi sonuçlar verdiklerini görmekteyiz.

7.1.3. Girdilerin belirlenmesi

YSA'ların dezavantajlarından birisi de ağı girilen girdilerin sayısının büyük olduğu durumlarda gereksiz ağırlıkların yeterli düzeyde belirlenememesidir. Gereksiz ağırlıklar belirlendiği takdirde ele alınan problemler analistler için daha anlaşılır ve çözümler daha verimli hale gelebilirler (Sexton ve diğ., 2004).

Sexton ve diğ. (2004) kaotik zaman serisinin tahmininde ağı girilen gereksiz girdilerin belirlemek için GA kullanılmışlardır. Ağırlıklar kodlanmış ve geni (ağırlığı) sifıra eşitleyen bir "*mutasyon 2*" operatörü eklenmiştir. Gizli katmandaki nöron sayısı da nöronlar birer birer eklenerek bulunmuştur. Önerilen model, gereksiz girdilerin belirlenmesi, analistler için problemin daha anlaşılabilir olmasını sağlaması ve etkin ve verimli bir ağ oluşturması açısından önemlidir. Ayrıca GA ve klasik GYA ile eğitilen YSA'ya göre daha iyi sonuç vermiştir.

Doganis ve diğ. (2006) raf ömrü kısa olan gıdaların satış tahmini için girdi olarak kullanılacak değişkenlerin belirlenmesinde GA'yı kullanmışlardır. Önerilen model doğrusal ve doğrusal olmayan modellerin kombinasyonu olan tahmin modellerine göre daha iyi sonuç vermiştir.

7.2. Modelin Algoritması


Bu çalışmanın hedefinde tahmin modellerinde klasik modellerden daha iyi sonuç veren GYA'nın parametrelerinin optimize edilerek iyileştirilmesi önemli bir rol oynamaktadır. Wang ve Huang (2007)'ın bulduğu sonuçlardan hareketle GYA'nın parametrelerinin ve ağ yapısının iyileştirilmesinde GA kullanılmıştır. Model hidroelektrik enerji üretiminin ve ithal edilen enerjinin tahmininde kullanılmış ve sonuçları değerlendirilmiştir. Önerilen modelin adımları Şekil 7.1'de verilmektedir.

Modelin ilk adımı GYA'nın optimize edilecek parametrelerini belirlemektir. GYA ile yapılan uygulamaların en büyük problemi modelin yapısının belirlenmesidir. Beklenen sonuç, modelin gerekenden basit ya da karmaşık olmamasıdır. Yapının belirlenmesinde ise gizli katman sayısı ve gizli sinir hücresi sayısı yer almaktadır. Yapılan tahmin çalışmalarının büyük bir bölümünde tek gizli katman kullanılmış ve tek gizli katmanın yeterince iyi sonuç verdiği belirtilmiştir (Sexton ve diğ, 1999-2000). Önemli olan gizli katmandaki gizli sinir hücresi sayısını belirlemektir.

Uygulamalarda karşılaşılan bir başka problem ise GYA'nın lokal optimuma takılmasıdır. GYA gradyan inişi bir algoritmadır ve gradyan inişi algoritmalarında global optimumu bulması başlangıç noktasına bağlıdır. GYA'da başlangıç ağırlıkları rassal belirlenir. Bu yüzden GYA tekrar tekrar çalıştırılarak farklı başlangıç ağırlıkları ile başlatılır ve lokal optimuma takılmasının önüne geçilmeye çalışılır.

Bir başka problem de öğrenme oranının belirlenmesidir. Öğrenme oranının gerekenden büyük olması modelin lokal optimuma takılması riskini yükseltirken, küçük olması da öğrenmenin yavaşlamasına neden olur (Alpaydın, 2004). Optimum öğrenme oranının bulunması için GYA her seferinde farklı bir öğrenme oranıyla tekrar tekrar çalıştırılır ve uygun bir öğrenme oranı bulunur.

Yukarıda bahsedilen nedenlerden dolayı bu çalışmada gizli katmandaki sinir hücresi sayısı, başlangıç ağırlık değerleri ve öğrenme oranı GA ile geliştirilerek optimum sinir ağı yapısı bulunmaya çalışılacaktır. Girdiler ve optimize edilecek parametreler belirlendikten sonra algoritmanın adımları genetik algoritmanın adımlarına benzemektedir. Ancak uygunluk fonksiyonu, bireyin kodlanması,



Şekil 7.1: Önerilen modelin algoritmasını gösteren akış diyagramı

çaprazlama ve mutasyon operatörleri klasik genetik algoritmalarından farklılık göstermektedir.

Modelin ayrıntıları aşağıda adımlar halinde anlatılmaktadır.

Adım 1: Tahminde kullanılacak olan veri eğitim, gerçekleştirme ve test verisi olmak üzere 3 gruba ayrılır. Eğitim verisi ağı eğitmek için, gerçekleştirme verisi modelin yapısına karar vermek için, test verisi ise modelin performansının ölçülmesinde kullanılacaktır. Veriler 0 ile 1 arasında normalize edilirler böylece farklı ölçeklere sahip olan değişkenler aynı ölçeğe getirilmiş olur.

Adım 2: Gerçekleştirme verisi ile bulunan göreceli hata (RE) değeri uygunluk fonksiyonudur. RE değeri birimsiz olduğu için iki YSA'nın performans karşılaştırmasında uygunluk fonksiyonu olarak kullanılacaktır.

Adım 3: Her birey bir sinir ağıdır. Sinir ağları tek gizli katmandan oluşmaktadır. Modelin yapısına göre girdi ve çıktı katmandaki sinir hücresi sayısı kullanıcı tarafından girilir. Karmaşık problemler için hareket fonksiyonunun doğrusal olmaması önemlidir. Hareket fonksiyonunun şekli ağıın genel performansına çok az etki eder (Şahin, 2002). Türevi kolay alınabildiği için hareket fonksiyonu olarak lojistik fonksiyon kullanılır.

Her sinir ağı önce GYA ile eğitilir. Kullanıcı tarafından belirlenen bir MSE (hata karesinin ortalaması) değerine ya da maksimum iterasyon sayısına ulaşıncaya eğitim durur. GYA sonucunda bulunan değer normalize edilmiş bir değerdir. Bulunan değer tekrar eski haline getirilir ve gerçekleştirme verisi kullanılarak her birey için bir RE değeri bulunur. Amaç gerçekleştirme verisi ile bulunan hata değerinin minimizasyonudur.


Adım 4: Durma kriteri olarak maksimum nesil sayısı belirlenir. Maksimum nesil sayısına ulaşıldığında algoritma son bulur.

Adım 5: Bireyler gerçek değerli kodlanır. Örnek bir sinir ağı ve bu sinir ağının kromozom yapısı Şekil 7.2'de gösterilmektedir. Bireyin kromozomu üç bölümden oluşur. İlk bölüm gizli katmandaki sinir hücresi sayısını, ikinci bölüm başlangıç ağırlıklarını, üçüncü bölüm ise öğrenme oranını gösterir. Çözüm uzayını belirleyecek olan üç karar değişkeni ve alabilecekleri değerler Tablo 7.2'de gösterilmektedir. Gizli sinir hücresi sayısı, başlangıç ağırlık değerleri ve öğrenme oranı optimum çözüme ulaşmak üzere bireyin gen yapısını oluşturmaktadırlar.


Tablo 7.2: GYA'nın parametreleri ve alabilecekleri değer aralıkları

Karar Değişkeninin Adı	Aralık
Gizli sinir hücresi sayısı	$[1, n]$ tamsayı
Başlangıç ağırlık değerleri	$[-0,01; 0,01]$
Öğrenme oranı	$(0, 1)$

Sinir Ağı



Kromozom



Şekil 7.2: Örnek bir sinir ağı ve kromozom yapısı

Her bireyin gizli sinir hücresi sayısını belirten geni 1 ile n arasında bir tamsayı değeri alır. n gizli sinir hücresi sayısının alabileceği maksimum değerdir ve kullanıcı tarafından belirlenir. Başlangıç ağırlıklarının $[-0,01; 0,01]$ gibi küçük bir aralıkta seçilmesi sigmoid fonksiyonun türevinin alınabilir olması açısından önemlidir. Eğer büyük değerlerle başlanırsa sigmoid fonksiyonun türevi 0 'a çok yakın olur ki bu da öğrenmenin olmaması anlamına gelir.

Tek gizli katman olduđu için ağırlıklar, girdi-gizli katmanları arasındaki ağırlıklar ve gizli-çıktı katmanları arasındaki ağırlıklar olmak üzere iki matristen oluşur. Şekil 7.2’de görülen örnekte girdi sinir hücresi sayısı 2, gizli sinir hücresi sayısı 2 ve çıktı hücresi sayısı 1 olan bir YSA modelinde bu matrisler sırasıyla 2x2 ve 2x1 boyutundadır. Öğrenme oranı (0,1) aralığında değeri alır. 0’a yakın bir öğrenme oranı ağırlık öğrenmesini yavaşlatırken, lokal optimuma takılma olasılığını azaltır; 1’e yakın öğrenme oranı ise öğrenmeyi hızlandırdığı için lokal optimuma takılma riski daha büyüktür. Farklı uygulamalarda parametrelerin alabileceği değerler kullanıcı tarafından değiştirilebilir.


Adım 6: Popülasyondaki birey sayısı, çaprazlama olasılığı (p_c) ve mutasyon olasılığı (p_m) belirlenir.

Adım 7: Başlangıç popülasyonun büyüklüğü belirlenir ve oluşacak diğer popülasyonlar için bu sayı sabittir. Başlangıç popülasyonu rassal olarak atanan bireylerden oluşur. Başlangıç popülasyonunda gizli katmandaki sinir hücresi sayısı 1 ile n arasında bir rassal tamsayı değeri alırken, başlangıç ağırlıkları $[-0,01; 0,01]$ aralığında ve öğrenme oranı da $[0, 1]$ aralığında düzgün dağılıma uyan rassal değerler alır.

Adım 8: Uygunluk değerlerine göre her birey için bir olasılık değeri bulunur ve rulet çemberi yöntemi ile seçim yapılır.

Adım 9: p_c olasılığına göre çaprazlama için popülasyondan bireyler seçilir ve çaprazlama gerçekleşir. Çaprazlama işlemi yalnızca başlangıç ağırlıklarını temsil eden genler üzerinde gerçekleşir. Çaprazlama için popülasyondan iki birey rassal olarak seçilir. Seçilen ebeveynlerden eşit miktarda gizli sinir hücresi seçilir ve birinci ebeveynin gizli sinir hücreleri ikinci ebeveynin seçilen gizli sinir hücrelerinin yerine, ikinci ebeveynin gizli sinir hücreleri de birinci ebeveynin gizli sinir hücrelerinin yerine geçer. Hangi gizli sinir hücrelerinin yer değiştireceği rassal olarak belirlenir. Bireylerin kromozom uzunlukları farklı olabileceğinden çaprazlamada yer değiştirecek sinir hücresi sayısı kısa kromozom uzunluğuna sahip ebeveyne göre yapılır. Çaprazlama işleminden sonra bireylerin uzunluğu değişmeden kalır. Şekil 7.3 gizli sinir hücresi sayısı 3 ve 4 olan iki bireyin çaprazlamasını göstermektedir. Bireylerin girdi ve çıktı sinir hücresi sayıları sırayla 2 ve 1’dir. Kaç adet sinir hücresinin yer değiştireceği 3 gizli sinir hücresine sahip olan birey tarafından

belirlenir. 1 ile 3 arasında rassal bir tamsayı seçilir ve seçilen sayıda rassal hücre diğer bireyin seçilen sayıda rassal hücresi ile yer değiştirir. Örnekte belirlenen rassal tamsayı 1'dir ve her iki bireyin rassal 1 gizli sinir hücresi yer değiştirmiştir. Çaprazlama sonucunda sinir hücresinin yer değiştirmesiyle başlangıç ağırlıkları da yer değiştirir ve yine 3 ve 4 sinir hücresine sahip iki çocuk oluşur.



Şekil 7.3: Önerilen model için bir çaprazlama örneği

Adım 10: Bireyler p_m olasılığına göre mutasyona uğrar. Mutasyona uğrayacak olan bireyde 3 tip mutasyon gerçekleşebilir:

- i. Mutasyon için seçilen gen, gizli katmanın sinir hücresi sayısını gösteren gen ise 1 ile n arasında rassal bir tamsayı değeri genin yeni değeri olur. Eğer mutant bireydeki sinir hücresi sayısı eskisinden fazlaysa eklenen sinir hücresi sayısı kadar bu sinir hücrelerini girdi ve çıktı hücrelere bağlayan yeni ağırlıklar eklenir, eski ağırlıklar olduğu gibi kalır. Eklenen hücrelerin değerleri de rassal olarak belirlenir. Mutasyon sonrasında oluşan yeni sinir hücresi sayısı eski değerinden küçükse çıkarılması gereken sayıda hücre ağdan çıkarılır. Çıkarılan

sinir hücreleri rassal belirlenir. Çıkarılan hücrelerin başlangıç ağırlıkları da hücre ile birlikte silinmiş olur.

- ii. Başlangıç ağırlıklarının yer aldığı gen mutasyona uğrarsa ağırlıklardan biri rassal olarak seçilir ve ortalaması 0 standart sapması 1 olan bir rassal değer ağırlığa eklenir (Rooij ve diğ., 1996).
- iii. Öğrenme oranının yer aldığı gen mutasyona uğrarsa (0, 1) aralığında düzgün dağılıma uyan rassal bir değer genin yeni değeri olur.

Adım 11: Seçim, çaprazlama ve mutasyonla oluşan bireylerin ve eski popülasyondaki bireylerin arasından uygunluk değerlerine göre en güçlü bireyler (popülasyon büyüklüğü kadar) alınır ve yeni popülasyon oluşturulur.

Adım 12: Maksimum nesil sayısına ulaşıldıysa Adım 13'e gidilir, ulaşılmadıysa Adım 8'e dönülür.

Adım 13: Optimum parametre ve yapıya sahip sinir ağına test verileri girilerek göreceli hata değeri (RE) bulunur.

Adım 14: Bulunan hata değerine bakılarak modelin iyi bir tahmin edici olup olmadığı araştırılır.

Adım 15: Test verileri ile elde edilen hata değeri istenildiği kadar küçükse, oluşturulan yapay sinir ağı modeli ile gelecek senelerin değerleri tahmin edilir.

Modelin kodları MATLAB programlama dilinde yazılmıştır (**Ek A**).

7.3. Modelin Diğer Tahmin Yöntemlerinden Farkı

Bu çalışma kapsamında YSA'nın klasik istatistiksel tekniklere göre tercih edilmesinin sebebi herhangi bir varsayıma gerek duymaması ve doğrusal olmayan problemlerin çözümünde başarılı sonuç vermesidir. Literatürdeki tahmin çalışmalarına bakıldığında YSA'nın kullanımının arttığını görmekteyiz (Tablo 3.1).

YSA'ların yapısı ve parametrelerinin modelin performansını etkilediği göz önüne alındığında ve yapılan çalışmalar incelendiğinde GA ile parametrelerin optimize edilmesinin modelin sonucunda iyileşme sağlayacağını göstermiştir. Önerilen modelde GA'nın kullanılmasındaki ana neden optimum bir yapay sinir ağı modeli geliştirmektir. Optimize edilen parametreler farklı çalışmalarda farklı kombinasyonlarda seçilmiştir (Tablo 7.1). Bu çalışmada seçilen üç karar değişkeni

(gizli sinir hücresi sayısı, başlangıç ağırlıkları ve öğrenme oranı) incelenilen çalışmalarda rastlanmayan bir kombinasyon olmuştur. Bu açıdan bakıldığında bu çalışma sadece enerji konusunda değil genel olarak tahmin konusunda da yeni bir araç sunmaktadır.

Öte yandan uygunluk fonksiyonu yapay sinir ağının eğitimi olan bir genetik algoritma modeli geliştirilmiştir. Önerilen bu modelde GA'nın klasik operatörleri (tek nokta çaprazlama vs) yerine tamamen probleme özgü çaprazlama ve mutasyon operatörleri kullanılmıştır. Bireyin kromozom yapısı homojen bir yapıya sahip değildir. Örneğin gizli sinir hücresini temsil eden ilk gen 1 ile n aralığında bir tamsayı değeri alırken, başlangıç ağırlıklarını veren genler -0,01 ile 0,01 arasında değerler alır. Bireyler gerçek değerlerle kodlandığı için farklı yapıdaki genlere farklı mutasyon ve çaprazlama operatörleri uygulanır.

8. MODELİN UYGULANMASI

8.1. Örnek Seçimi

Türkiye'nin enerji arzında dışa bağımlı olması gelişiminin önünde büyük bir engeldir. Bir ülkenin yerel enerji kaynaklarının çeşitliliği kalkınmasının sürdürülebilirliği açısından önem taşımaktadır. Türkiye'nin büyük bir hidroelektrik potansiyele sahip olması ve bu potansiyeli değerlendirememesi, hidroelektrik konusunda çeşitli araştırmaları ve yatırımları beraberinde getirmiştir.

Hidroelektrik üretimini önemli kılan diğer bir etmen ise küresel ısınmaya sebep olan fosil yakıtlara alternatif olmasıdır. Küresel ısınma için önerilen en etkin çözüm yolu hidroelektrik enerjinin de yer aldığı yenilenebilir enerji kullanımıdır.

Bölüm 7'de önerilen tahmin modeli hidroelektrik enerji üretimi ve ithal edilen enerji miktarının tahmininde kullanılmıştır. Bulunan sonuçlar ışığında Türkiye'nin gelecekteki hidroelektrik enerji üretim durumu ve uygulaması gereken enerji politikalarına dair bir çıkarım yapılabilecektir.


8.2. Hidroelektrik Enerji Üretim Tahmini

8.2.1. Girdilerin belirlenmesi

Hidroelektrik santrallerinin arıza, bakım ve verimlilik değerleri ile akarsular üzerindeki kurulu güç miktarı hidroelektrik üretimini etkileyen faktörler arasındadır (Eroğlu, 2006). Munoz ve Sailor (1998)'a göre küresel ısınma, kuraklık, yağış, buharlaşma, akarsuların akış miktarı, sıcaklık, nem, radyasyon, rüzgarın hızı ve toprağın nem durumu hidroelektrik üretimini etkileyen iklimsel değişkenlerdir. Hidroelektrik üretimi yağış, buharlaşma, sıcaklık, nem ve diğer iklimsel parametrelere bağlı olan akış miktarına bağlıdır. Yağış miktarındaki değişim üretilebilecek hidroelektrik miktarını büyük ölçüde etkileyebilir. Aynı çalışmada suyun tüketim amaçlı kullanım miktarı, suyun dağıtımı ve hidroelektrik santralinin üzerinde bulunduğu akarsuyun akış yönünde bir nükleer santralin olup olmaması da iklimsel olmayan ancak hidroelektrik üretimini etkileyen faktörler olarak yer almaktadır.

Hidroelektrik üretimini etkileyen faktörlerden biri de elektrik tüketimidir. Kermanshahi ve Iwarniya (2002) ise elektrik tüketimini etkileyen faktörler olarak nüfus, hane sayısı, elektrik fiyatları, havadaki CO₂ miktarı, endüstriyel üretim miktarı, petrol fiyatları, enerji tüketimi, ve gayri safi yurtiçi hasıla (GSYH) değerlerini almışlardır.

1970–2004 yılları arası veriler ancak elektrik tüketimi, GSYH, enerji tüketimi, kurulu güç, nüfus girdileri için bulunabılmıştır. Hidroelektrik üretimi tahmini için bu beş değişken modelin girdilerini oluşturmaktadır. Hidroelektrik üretiminin tahmini için kullanılacak olan örnek bir YSA modeli Şekil 8.1’de görülmektedir. Girdileri elektrik tüketimi, GSYH, enerji tüketimi, kurulu güç ve nüfus olan sinir ağının gizli sinir hücresi sayısı, başlangıç ağırlıkları ve öğrenme oranı ilerleyen bölümlerde önerilen model ile belirlenecektir.




Şekil 8.1: Hidroelektrik üretimi tahmininde kullanılacak olan yapay sinir ağı modeli

8.2.2. Veri özellikleri

Çalışmada kullanılan veriler çeşitli kaynaklardan alınmıştır. Hidroelektrik üretimi, kurulu güç ve elektrik tüketimi verileri Türkiye Elektrik İletim A.Ş. (TEİAŞ)’den, nüfus ve GSYH verileri T.C. Merkez Bankası’ndan ve enerji tüketimi verileri Enerji ve Tabii Kaynaklar Bakanlığı (ETKB)’nden alınmıştır. Tüm veriler 1970-2004 arası yıllık verilerdir (**EK B**).

Hidroelektrik enerjinin üretim ve tüketim miktarlarına bakıldığında birbirine eşit olduğu görülmektedir (DEK-TMK, 2006). Bu nedenle hidrolik enerjinin üretim miktarını tahmin etmek aynı zamanda tüketim miktarını tahmin etmektir. Şekil 8.2’ de 1970-2005 yıllarında Türkiye’nin hidroelektrik üretim grafiği görülmektedir.



Şekil 8.2: 1970-2005 yılları arası Türkiye’de hidroelektrik üretimi

1970 yılından bu yana hidroelektrik üretimi genel olarak artan bir trend izlemiştir. Ancak 70’lerden bu yana önemli saptamalara sebep olan olaylar yaşanmıştır. 1999 Düzce ve Adapazarı depremleri ile 2000-2001 ekonomik krizi ekonomik hayatı ve yatırımları etkilemiş, dolayısıyla elektrik enerjisi talebi de düşmüştür. Hidroelektrik üretimini etkileyen faktörlerden biri de elektrik talebidir. Bu yıllarda hidroelektrik üretiminde yaşanan azalma elektrik talebindeki azalışla açıklanabilir. 2001 yılı ve sonrasında yaşanan aşırı kuraklık da hidroelektrik üretimini olumsuz yönde etkileyen iklimsel nedendir. (Ünsal ve Önöz, 2006).

8.2.3. Uygun YSA Yapısını Belirleme

Önerilen model hidroelektrik üretiminin tahmininde kullanılmak üzere uygun bir yapay sinir ağı yapısına karar verme aşamasında kullanılmış ve karar verilen sinir ağı modeli ile gelecek 6 yılın hidroelektrik üretim tahmini gerçekleştirilmiştir.

Uygun sinir ağı yapısına karar vermede istatistiksel olarak anlamlı bir sonuç elde edilebilmesi için model 30 kez çalıştırılmıştır. Uygulamanın sonuçlarını gösteren tablo **Ek C**’de verilmiştir. Bölüm 8.2.1’de belirtildiği gibi hidroelektrik üretiminin tahmininde 5 girdi kullanılmıştır. En iyi sonucu uygunluk değeri 0,3912 olan ve 5 girdi hücresi, 3 gizli sinir hücresi ve 1 çıktı hücresinden oluşan sinir ağı modeli vermektedir. Bulunan 30 çözümün de gizli sinir hücresi sayısı 3’tür. Ancak başlangıç

ağırlıkları ve öğrenme oranı farklılık göstermektedir. Modelin verdiği en iyi sonuca göre 3 gizli katmandan oluşan sinir ağının başlangıç ağırlıkları Tablo 8.1 ve 8.2’de görülmektedir. Örneğin birinci girdi hücresi ile birinci gizli sinir hücresi arasındaki başlangıç ağırlığı 0,0007’dir. Aynı şekilde Tablo 8.2’ye bakıldığında birinci gizli sinir hücresi ile birinci çıktı hücresi arasındaki başlangıç ağırlığı -0,0033’tür. Ayrıca GYA’da kullanılacak olan öğrenme oranı 0,0882 bulunmuştur.

Tablo 8.1: Hidroelektrik tahmininde kullanılan modelin girdi sinir hücreleri ile gizli sinir hücreleri arasındaki başlangıç ağırlıkları

	x_1	x_2	x_3	x_4	x_5
1.g.s.h.*	0,0007	0,0012	0,0007	-0,0006	-0,0018
2.g.s.h.	-0,0006	-0,0044	-0,0020	-0,0044	-0,0008
3.g.s.h.	0,0041	-0,0008	0,0047	0,0040	0,0047

* 1. g.s.h.: birinci gizli sinir hücresi

Tablo 8.2: Hidroelektrik tahmininde kullanılan modelin gizli sinir hücreleri ile çıktı sinir hücreleri arasındaki başlangıç ağırlıkları

	1.g.s.h.	2.g.s.h.	3.g.s.h.
y	-0,0033	0,0001	-0,0033

8.2.4. Çıktı Hesapları

Bulunan en iyi yapay sinir ağı modeli son beş yılın (2000-2004) verisi ile çalıştırılarak test edilmiştir. Test verisi ile bulunan göreceli hata değeri 0,2169 bulunmuştur. Bu hata değeri modelin hidroelektrik üretiminin tahmininde başarı ile kullanılabileceğini göstermektedir.

Model eğitildikten sonra bulunan ağırlık değerleri Tablo 8.3 ve 8.4’te görülmektedir. Bulunan nihai ağırlıklardan yola çıkarak hidroelektrik üretimini etkileyen faktörlerin önem sırası belirlenebilir.

Tablo 8.3: Girdi sinir hücreleri ile gizli sinir hücreleri arasındaki nihai ağırlıklar

	x_1	x_2	x_3	x_4	x_5
1.g.s.h.	-13,6670	-11,9360	11,9866	12,3170	-9,6076
2.g.s.h.	6,2649	7,0838	-14,8130	0,8895	4,9170
3.g.s.h.	-6,1199	0,6242	-10,3250	12,6339	0,3625

Tablo 8.4: Gizli sinir hücreleri ile çıktı sinir hücreleri arasındaki nihai ağırlıklar

	1.g.s.h.	2.g.s.h.	3.g.s.h.
y	2,9015	3,791	-10,764

YSA'da girdilerin önem sıralamasını veren çeşitli yöntemler geliştirilmiştir. Bu yöntemlerden en sık kullanılan 3'ü şu şekildedir (Şahin, 2002):

1. Girdi sinir hücrelerini gizli sinir hücrelerine bağlayan ağırlıklardan mutlak değeri 0'a yakın olanlar az öneme sahiptir. Mutlak değerce büyük değerlere sahip olan girdi hücrelerinin önemi de büyüktür. Gizli sinir hücreleri ile çıktı hücreleri arasındaki ağırlıkları göz önüne almadığından bu yöntem sağlıklı sonuçlar vermeyebilir. Örneğin bir girdiyi gizli sinir hücresine bağlayan ağırlık yüksekken, gizli sinir hücresini çıktı hücreye bağlayan ağırlık düşük bir değerse girdinin çıktı üzerindeki önemi azalacaktır.
2. Duyarlılık analizi yapılabilir. Duyarlılık analizi girdilerden biri sabit tutulup çıktı üzerindeki etkisi incelenerek yapılır. Belirli bir girdi sabit tutulduğunda hata oranında azalma gözlenmiyorsa o girdinin önemli olmadığı sonucuna varılabilir.
3. Belirli bir girdi ve çıktı arasındaki tüm ağırlıkların, tüm girdi-çıkta değişkenleri arasındaki toplam ağırlığa oranı da girdilerin önem sıralamasını veren bir yöntemdir.

$$RS_{ji} = \frac{\sum_{k=0}^n (w_{ki} \cdot v_{jk})}{\sum_{i=0}^m \left| \sum_{k=0}^n (w_{ki} \cdot v_{jk}) \right|} \quad (8.1)$$

RS_{ji} , i girdisi ile j çıktısı arasındaki bağın kuvvetidir bir başka deyişle j çıktısı için i girdisinin önem derecesidir; w_{ki} , i girdi hücresi ile k gizli sinir hücresi arasındaki ağırlıktır; v_{jk} ise k gizli sinir hücresi ile j çıktı hücresi arasındaki ağırlıktır. Şahin (2002), önem dereceleri toplamının 1'e eşitlenerek formülün daha etkin bir hale gelmesi için aşağıdaki şekilde kullanmıştır.

$$RS_{ji} = \frac{\left[\sum_{k=0}^n (w_{ki} \cdot v_{jk}) \right]^2}{\sum_{i=0}^m \left[\sum_{k=0}^n (w_{ki} \cdot v_{jk}) \right]^2} \quad (8.2)$$

Bu çalışmada tüm ağırlıkları dikkate alan ve kısa sürede sonuca ulaşan üçüncü yöntem (Denklem (8.2)) girdiler arasındaki önem sıralamasının belirlenmesi için kullanılmıştır.

Girdilerin önem sıralaması için Tablo 8.3 ve 8.4’ deki değerler Denklem (8.2)’de yerine konulduğunda Tablo 8.5’ te görülen önem dereceleri bulunmuştur. Bu değerlere göre en önemli girdi kurulu güçtür. Kurulu güç oranında üretim yapılması beklenen bir durumdur çünkü üretimi belirleyen en önemli etken kapasitedir. İkinci olarak enerji tüketimi ve hemen arkasından elektrik tüketimi gelmektedir. Bu durum üretimi tetikleyen durumun talep olduğunu bir kez daha göstermektedir. GSYH ve nüfus girdilerinin ise hidroelektrik üretimi üzerindeki etkilerinin düşük olduğu görülmektedir.

Tablo 8.5: Girdilerin önem dereceleri

Girdi adı	Önem derecesi
Kurulu güç (x_4)	0,461861
Enerji tüketimi (x_3)	0,396429
Elektrik tüketimi (x_1)	0,122878
GSYH (x_2)	0,010339
Nüfus (x_5)	0,008493

8.2.5. Performans Analizi

Önerilen model ile bulunan uygun YSA modelinin test verisi ile bulunan sonuçları klasik GYA ile eğitilen YSA modelinin bulduğu sonuçlarla karşılaştırılmıştır. Klasik YSA’da başlangıç ağırlıkları rassal atanmakta ve gizli nöron sayısına denenerek karar verilmektedir. Karşılaştırma modeli olarak kullanılan YSA modelinin gizli sinir hücresi sayısına karar vermek için 1 ile 30 arasında gizli sinir hücresine sahip 30 farklı YSA modelinin her biri 100 kere çalıştırılmıştır. Gerçekleme verisi ile bulunan sonuçlara göre en iyi sonucu 3 gizli nöron sayısına sahip olan YSA vermiştir. Öğrenme oranı da 0,1 olarak alınmıştır (Alpaydın, 2004).

Önerilen modelin bulduğu uygun YSA modelinin de gizli sinir hücresi sayısı 3’tür. Ancak önerilen modelde başlangıç ağırlıkları ve öğrenme oranı farklı bulunmuştur. Karşılaştırma için kullanılan model test verisi ile çalıştırıldığında göreceli hata değeri 0,3852 bulunmuştur. Bu değer önerilen model ile bulunan hata değerinden (0,2169) daha yüksek bir değerdir. Önerilen model ile test verisi üzerinde yapılan tahmin daha

iyi sonuç vermiştir. Bu sonuçtan yola çıkarak önerilen modelin tahmin için uygun bir araç olduğunu söyleyebiliriz.

8.2.6. Tahmin

Uygun YSA modeline karar verildikten sonra, model kullanılarak hidroelektrik üretimi tahmini yapılmıştır. Hidroelektrik üretiminin gelecek değerleri girdilerin gelecek değerlerine bağlı olduğundan öncelikle girdi değişkenlerinin gelecek değerleri tahmin edilmiştir. Girdi değişkenlerinin gelecek değerlerinin tahmininde de önerilen algoritma kullanılmıştır. Tahminin girdisi ise geçmiş değerler olmuştur. Örneğin hidroelektrik üretimin girdisi olan GSYH'nın gelecek değerleri, YSA ile tahmin edilirken geçmiş yıllardaki değerleri modelin girdisini oluşturur.


Bu yaklaşımın bazı dezavantajları vardır. 2005 yılındaki tahmin değeri gerçek değerler kullanılarak tahmin edilirken, 2006 ve sonraki değerlerin tahmininde tahmin edilmiş değerler kullanılacaktır. Bu durumda da tahmin edilecek yılların sayısı arttıkça tahminin güvenilirliği azalacaktır. Bu nedenle bu çalışma kapsamında 6 yılın tahmini yapılmış, en son 2010 yılının üretim ve ithalat değerleri tahmin edilmiştir.

Ayrıca tahminde kaç yıl öncesinin değerlerinin kullanılacağı da önemlidir. Yalnızca bir önceki senenin değerinden yola çıkarak geleceği tahmin etmek YSA için elverişli bir durum değildir. Çünkü veride bir trend varsa, bir sene öncesinden bu trendi yakalaması güçtür. Bu yüzden sırasıyla 2, 3 ve 4 yıl geriye gidilerek tahmin yapılmıştır. 4 yıldan daha fazlası alınmamasının nedeni, son 4 yılın trendi yeterince iyi temsil edebileceğinin düşünülmesi ve veri sayısının az olmasıdır.

Önerilen model, girdi değişkenlerinin tahmininde uygun bir YSA yapısı belirlemek için kullanılmıştır. Çıkan sonuçlar her değişken için karşılaştırılmış ve en az hataya sahip olan model belirlenmiştir. Bu sayede kaç yıl öncesinin modele girdi olacağı da belirlenmiştir. Hidroelektrik enerji üretim tahmininde girdi olarak kullanılan nüfus değişkeni doğrusal olarak değiştiği için YSA'ya gerek kalmadan SPSS paket programı ile doğrusal regresyon modeli kullanılarak 2010 yılına kadar tahmin edilmiştir. Elektrik tüketimi, GSYH, enerji tüketimi ve kurulu güç değişkenlerinin tahmini için ise önerilen model ile uygun YSA modeli belirlenmiş ve 2010 yılına kadar olan değerleri tahmin edilmiştir. GSYH ve kurulu güç için 2, elektrik tüketimi için 3 ve enerji tüketimi için 4 yıl önceki değerler kullanılarak girdiler tahmin edilmiştir.

Girdilerin gelecek deęerleri tahmin edildikten sonra, hidroelektrik enerji üretimi Bölüm 8.2.3'te bulunan uygun YSA modeli ile tahmin edilmiştir. Şekil 8.3 hidroelektrik enerji üretiminin 2005-2010 yıllarındaki tahmin deęerlerini göstermektedir. Şekilde de görüldüğü gibi hidroelektrik üretiminin genel olarak bir artış göstereceğı söylenebilir. 2009 yılında üretimde ani bir düşüş gözlenmektedir. 2005 yılında başlayan artış 2010 yılına kadar devamını koruyamayacak, belirli bir aralıkta üretim dengesini koruyacaktır.

İthalat tahmini yapmak bu noktada önem kazanmaktadır. 2010 yılına kadar artış göstermeyen hidroelektriğin bu durgunluğunun ithalat üzerindeki etkisine bakılacaktır.




Şekil 8.3: 2005-2010 yılları arası hidroelektrik üretim tahmini

8.3. Enerji İthalatı

8.3.1. Girdilerin belirlenmesi

Enerji ithalatının tahmini için de ithalatı etkileyen faktörlerin belirlenmesi gerekir. Adams ve Shachmurove (2007) Çin'in enerji ithalatının tahmininde GSYH ve enerji tüketimini kullanmışlardır. Enerji tüketimi enerji arzını da beraberinde getirir ki bu da ithalat miktarını etkileyen en temel faktörlerden biridir. GSYH ise söz konusu ülkenin gelirinin bir göstergesidir ve ithalat miktarını etkileyen önemli bir unsurdur.




Şekil 8.4: Enerji ithalatı tahmininde kullanılacak olan yapay sinir ağı modeli

Bu çalışma kapsamında da enerji ithalatı tahmini için bağımsız değişkenler GSYH ve enerji tüketimi olarak alınacaktır. Parametreleri GA ile bulunacak olan ve girdileri GSYH ve enerji tüketimi olan örnek bir YSA modeli Şekil 8.4’de görülmektedir.


8.3.2. Veri özellikleri

Birincil enerji ithalatı verileri Dünya Enerji Konseyi Türk Milli Komitesi (World Energy Council Turkish National Committee)’nden alınmıştır. İthalat tahmininde kullanılacak olan GSYH ve enerji tüketimi verilerinin kaynakları Bölüm 8.2.2’de belirtilmiştir.


Türkiye’de 1970-2004 yılları arasında gerçekleşen enerji tüketimi Şekil 8.5’ te, ithal edilen birincil enerji kaynakları ise Şekil 8.6’da görülmektedir. Toplam enerji tüketimi giderek artmıştır. Bunu takiben ithal edilen enerji miktarı da giderek artan bir trend izlemiştir. İthal edilen enerjinin tüketilen enerjiye oranı 1970 yılında %24,6 iken 2004’e gelindiğinde %77,3’e çıkmıştır. Şekil 8.7’de Türkiye’nin 1970–2004 yılları arası enerji ithalatının enerji tüketimindeki payı yer almaktadır ve Türkiye’nin enerjide dışa bağımlı bir ülke olduğu görülmektedir.



Şekil 8.5: 1970-2005 yılları arası Türkiye’de toplam birincil enerji tüketimi



Şekil 8.6: 1970-2005 yılları arası Türkiye’de ithal edilen birincil enerji



Şekil 8.7: 1970-2004 yıllarında Türkiye’de ithalatın enerji tüketimindeki payı

8.3.3. Uygun YSA Yapısını Belirleme

Hidroelektrik tahmininde yapıldığı gibi ithalat tahmini için de uygun sinir ağı yapısına karar vermede istatistiksel olarak anlamlı bir sonuç elde edilebilmesi için model 30 kez çalıştırılmıştır. Uygulamanın sonuçlarını gösteren tablo **Ek D**’ de verilmiştir. En iyi değere sahip 5 sonuç bulunmuştur. Bu 5 sonuç aynı uygunluk değerine sahip olmalarına rağmen farklı kromozom yapılarına sahiptirler. Bu da farklı yapay sinir ağı modellerinin alternatif çözümler olarak bulunduğunu göstermektedir. Hangi modeli ithalat tahmini için kullanacağımıza karar vermek için tüm alternatif modeller test veri grubu ile denenmiş ve 5 adet hata değeri bulunmuştur. Bu 5 model arasında en düşük hata (RE) değerine sahip olan sinir ağı modeli tahminde kullanacağımız YSA modelidir. Tablo 8.6’da 5 model için test verisi ile bulunan RE değerleri verilmiştir. Model 1, 7 gizli sinir hücrelerine sahip olan model; Model 2, 10 gizli sinir hücrelerine sahip olan model; Model 3, 15 gizli sinir hücrelerine sahip olan model; Model 4, 18 gizli sinir hücrelerine sahip olan model ve Model 5, 25 gizli sinir hücrelerine sahip olan modeldir.

Tablo 8.6: Alternatif modellerin hata değerleri

	Model 1	Model 2	Model 3	Model 4	Model 5
RE	0,5569	0,103	0,5971	0,6206	0,4094

Test verileri ile bulunan en iyi sonuç 10 gizli sinir hücrelerine sahip olan modelin sonucunda bulunmuştur. Bu sonuçlar ışığında enerji ithalatının tahmininde kullanılması önerilen modelin başlangıç ağırlıkları Tablo 8.7 ve 8.8’ de verilmiştir. Önerilen modelin öğrenme oranı da 0,2425 olarak bulunmuştur.

Tablo 8.7: İthalat tahmininde kullanılan modelin girdi sinir hücreleri ile gizli sinir hücreleri arasındaki başlangıç ağırlıkları

	x_1	x_2
1.g.s.h.	-0,0003	0,0042
2.g.s.h.	-0,0014	0,0027
3.g.s.h.	0,0027	0,0005
4.g.s.h.	-0,0038	0,0022
5.g.s.h.	1,1983	0,0001
6.g.s.h.	-0,0049	0,0027
7.g.s.h.	-0,0049	-0,0014
8.g.s.h.	-0,0049	-0,0009
9.g.s.h.	-0,0049	0,0004
10.g.s.h.	0,0045	-0,0023

Tablo 8.8: İthalat tahmininde kullanılan modelin gizli sinir hücreleri ile çıktı sinir hücreleri arasındaki başlangıç ağırlıkları

	1.g.s.h.	2.g.s.h.	3.g.s.h.	4.g.s.h.	5.g.s.h.	6.g.s.h.	7.g.s.h.	8.g.s.h.	9.g.s.h.	10.g.s.h.
y	0,0049	1,1809	0,0044	-0,0003	-0,0014	0,002	0,0544	1,1809	0,0044	0,0031

8.3.4. Çıktı Hesapları

Bulunan en iyi yapay sinir ağı modeli son beş yılın (2000-2004) verisi ile çalıştırılarak test edilmiştir. Test verisi ile bulunan göreceli hata değeri 0,103 bulunmuştur. Bu hata değeri modelin enerji ithalatı tahmininde başarı ile kullanılabileceğini göstermektedir.

Model eğitildikten sonra bulunan ağırlık değerleri Tablo 8.9 ve 8.10’da görülmektedir. Bulunan nihai ağırlıklardan yola çıkarak enerji ithalatını etkileyen faktörlerin önem sırası belirlenebilir.

Tablo 8.9: Girdi sinir hücreleri ile gizli sinir hücreleri arasındaki nihai ağırlıklar

	x_1	x_2
1.g.s.h.	-1,1013	-2,3036
2.g.s.h.	5,5208	-3,6582
3.g.s.h.	3,9683	1,7372
4.g.s.h.	-4,3733	2,0338
5.g.s.h.	7,0178	-7,7071
6.g.s.h.	1,9810	-3,5423
7.g.s.h.	-2,2433	0,6868
8.g.s.h.	-1,1088	0,2627
9.g.s.h.	-37,484	-71,6520
10.g.s.h.	-20,941	37,2580

Tablo 8.10: Gizli sınır hücreleri ile çıktı sınır hücreleri arasındaki nihai ağırlıklar

	1.g.s.h.	2.g.s.h.	3.g.s.h.	4.g.s.h.	5.g.s.h.
y	-3,2921	-1,4779	-1,3492	1,4843	4,2004

	6.g.s.h.	7.g.s.h.	8.g.s.h.	9.g.s.h.	10.g.s.h.
y	-7,7821	-4,8561	-2,6594	-4,4844	0,3797


Girdilerin önem dereceleri Tablo 8.11’ de verilmektedir. Tabloya göre enerji tüketimi ve GSYH ithalatı önemli ölçüde etkilemektedir. Ancak elektrik tüketiminin ithalatı etkileme oranı daha yüksektir. Enerji tüketiminin artması ithalatın artışını da beraberinde getirmektedir. GSYH’nın artmasının ithalat üzerindeki pozitif etkisi de alım gücünün artması ile ithal edilen miktarın da artması olarak açıklanabilir.

Tablo 8.11: Girdilerin önem dereceleri

Girdi adı	Önem derecesi
Enerji tüketimi (x_2)	0,66003
GSYH (x_1)	0,33997

8.3.5. Tahmin

Hidroelektrik üretiminin tahmininde de girdi olarak kullanılan GSYH ve enerji tüketimi verilerinin gelecek değerlerinin tahmini Bölüm 8.2.5’te anlatılmıştı. Çıkan tahminler ve önerilen modelle bulunan uygun YSA modeli ile enerji ithalatının tahmini gerçekleştirilmiştir. Şekil 8.8, 2005-2010 yılları için yapılan enerji ithalat tahmin sonuçlarını göstermektedir.



Şekil 8.8: 2005-2010 yılları arası enerji ithalatı tahmini


Şekil 8.8’de de görüldüğü gibi enerji ithalatı bugüne kadar olduğu gibi yine artmaya devam edecektir. 2004’te 67.885 bTEP (bin ton eşdeğer petrol) olan enerji ithalatı 2010’da 83.000 bTEP’ e çıkacaktır. İthalatta yaklaşık %22’lere varan artış beklenmektedir.

8.4. Uygulama Sonuçları

Parametrelerinin genetik algoritmalar kullanılarak bulunduğu bir yapay sinir ağı modeli hidroelektrik üretimi ve enerji ithalatı tahmininde kullanılmıştır. Eğitim verisi ile ağı eğitilirken, gerçekleştirme verisi ile uygun YSA yapısı belirlenmiştir. Test verisi ile elde edilen sonuçlarda görülmüştür ki önerilen model yeterince iyi sonuçlar vermiştir.

Yapılan çalışmalar ışığında 2010 yılına kadar gerçekleşecek olan hidroelektrik üretimi ve enerji ithalatı ile bazı çıkarımlar yapmak mümkündür. Şekil 8.9’da ithalat ve hidroelektrik üretim tahminlerinin birlikte yer aldığı grafik görülmektedir. Hidroelektrik değerleri ithalat değerleri ile aynı birimde olması için bin ton eşdeğer petrol cinsinden yazılmıştır.

Grafikten de görüldüğü gibi Türkiye’nin ithalat değerleri artan trendini korumaktadır. Hidroelektrik üretiminde de bir artış söz konusu olmasına rağmen ithalattaki artış oranının hidroelektrik üretime göre daha fazla olduğu grafikten rahatlıkla yorumlanabilmektedir. Enerji talebinin hızla arttığı Türkiye’de, en önemli yenilenebilir yerli kaynağın değerlendirilmesindeki bu yavaş ilerleme dışa bağımlılığı giderek artırmaktadır.



Şekil 8.9: Hidroelektrik üretimi ve enerji ithalatı karşılaştırmalı grafiği

9. SONUÇ VE ÖNERİLER

Enerji, diğer ülkelerde olduğu gibi Türkiye için de ekonomik ve sosyal gelişim ve artan yaşam kalitesi için gereklidir. Dünyadaki enerjinin büyük bir bölümü üretim için kullanılmakta ancak hızla gelişen teknoloji nedeniyle bu kaynakların sürekliliği sağlanamamaktadır. Atmosfere salınan zararlı gazlar enerji üretimi, dağıtımı ve tüketiminin verimliliğine daha fazla odaklanması gerektiğini göstermektedir. Türkiye gibi gelişmekte olan ülkelerde, politikacılar ve yatırımcılar ekonomik büyümenin sağlanması ve hayat standartlarının geliştirilmesinde elektriğin temel rolü üzerinde daha fazla durmaya başlamışlardır.

Elektrik, üretim için en önemli girdilerden biridir ve ülkenin elektriğinin yerli kaynaklardan üretilmesi kalkınmanın sürekliliği açısından önemli ve gereklidir. Türkiye elektriğinin büyük bölümünü ithal kaynaklardan üretmektedir ve hidroelektrik potansiyelinin büyük bölümünü henüz kullanmamaktadır. Elektrik ürettiği enerji kaynaklarında dışa bağımlı olan Türkiye için kullanılmayan hidroelektrik enerji potansiyeli önemli bir çözüm olarak durmaktadır.

Hidroelektrik enerjiyi Türkiye için önemli kılan tek nokta potansiyelinin fazla olması değildir. Hidroelektrik enerji aynı zamanda yenilenebilir enerji kaynağıdır ve Türkiye'nin ithalatının büyük bir bölümünde yer alan fosil yakıtlara alternatif bir kaynaktır. Sadece ekonomik olarak değil çevresel faktörler açısından da Türkiye ve dünyada yenilenebilir enerji kaynaklarının kullanımının yaygınlaştırılması gerekmektedir. Yüksek yenilenebilir enerji potansiyeline rağmen, Türkiye'nin Kyoto Protokolünü imzalamayan ülkeler arasında olması düşündürücü bir konudur. Tüm dünya global ısınmanın neden olduğu çevresel felaketlere engel olma yolunda adım atarken Türkiye'nin bu yönde bir politika izlememesi gelecek kuşaklar için anlaşılması güç bir tutumdur. Bu noktada atılacak ilk adım en büyük potansiyele sahip olduğumuz ve en verimli elektrik üretim kaynağı olan hidroelektrik santrallerine yatırımların artırılması olabilir. Bu çalışmada görülmüştür ki Türkiye'nin enerjide dışa bağımlılığı giderek artmaktadır ve artmaya devam edecektir. İthalata yaptığımız yatırımların ülke içinde enerji üretimi için yapılması enerjide dışa bağımlılığımızı azaltabilir.

Hidroelektrik santralleri yatırımlarının artması ve yatırımcılara ışık tutması açısından gelecek çalışmalarda hidroelektrik potansiyelimizi kullanmanın ithalat ve elektrik üretiminde ne kadar ekonomik fayda sağlayacağına dair analizler yapılabilir.

Çalışmada tahmin modeli olarak parametreleri genetik algoritmalarla belirlenen yapay sinir ağları yaklaşımı kullanılmıştır. Gerek tek başına geri yayımlı algoritmalar, gerekse genetik algoritmalar yakın geçmişte tahmin için yeğlenen yöntemler olmuştur. Ancak bu çalışmada, iki yöntem birleştirilerek yeni bir tahmin algoritması tasarlanmıştır. Genetik algoritmalar ile yapay sinir ağının gizli sinir hücresi sayısı, başlangıç ağırlıkları ve öğrenme oranı parametreleri belirlenmiştir. Analizler, tüm girdi değişkenleri için verilerin elde edilebildiği dönem olan 1970-2004 arası yıllık veriler kullanılarak yapılmıştır. Modelin amacı geri yayımlı öğrenme algoritmasını iyileştirmektir. Tasarlanan modelin test veri kümesine uygulanması sayesinde elde edilen tahmin değerlerinde beklenen iyileştirmeyi gerçekleştirdiği saptanmıştır. Bu sonuç elde edildikten sonra 2007-2010 yılları arasında hidroelektrik üretimi ve enerji ithalatı tahminleri bu model uygulanarak yapılmıştır.

Çalışmada elde edilen sonuçlar göstermektedir ki, hidroelektrik üretimi henüz hızlı bir artışa geçemezken, ithalat geçmişteki hızında artışını sürdürmektedir. Ekonomik dengeyi bozan bu artışı durdurmanın en etkin yollarından biri hidroelektrik üretiminin hızla artırılmasıdır. Bu çalışmanın sonuçları enerji planlarında hidroelektrik üretim stratejilerine daha çok önem verilmesi gereğini vurgulamaktadır.

İleriki çalışmalarda yapay sinir ağının farklı parametreleri, genetik algoritmalar ya da başka arama algoritmaları ile belirlenebilir ve sonuçlar karşılaştırılabilir. Ayrıca, aylık verilerle yapılan analiz istatistiksel açıdan daha anlamlı olacağından, aynı yöntem aylık verilerle denenerek tekrarlanabilir. Çalışma ekonomik ağırlıklı olarak geliştirilebileceği gibi, hidroelektrik üretiminin enerji ithalatı üzerinde etkisine odaklanılarak tahminler yapılabilir.

Bu çalışmada tasarlanan model farklı tahmin uygulamalarında uygulanıp denenebileceği gibi farklı yapay sinir ağları uygulamalarında (örneğin sınıflandırma problemleri gibi) da denenebilir.

KAYNAKLAR

- Adams, F.G. and Shachmurove, Y.**, 2007. Modeling and forecasting energy consumption in China: Implications for Chinese energy demand and imports in 2020, *Energy Economics*, doi:10.1016/j.eneco. 2007.02.010.
- Akay D, Atak M.**, 2006. Grey prediction with rolling mechanism for electricity demand forecasting for Turkey, *Energy*, doi:10.1016/j.energy. 2006.11.014.
- Alpaydın, E.**, 2004. Machine Learning, Massachusetts Institute of Technology, USA.
- Altın, V.**, 2007. Enerji Dosyamız, *Tübitak Bilim ve Teknik*, Ocak 2007 Sayısı.
- Aras, H. and Aras, N.**, 2004. Forecasting Residential Natural Gas Demand, *Energy Sources*, **26**, 463–472.
- Azadeh, A., Ghaderi, S.F., Tarverdian, S. and Saberi, M.**, 2006. Integration of artificial neural Networks and genetic algortihm to predict electrical energy consumption, *Applied Mathematics and Computation*, doi:10.1016/j.amc.2006.08.093.
- Biroğul, S.**, 2005. Genetik Algoritma Yaklaşımıyla Atölye Çizelgeleme, *Yüksek Lisans Tezi*, Gazi Üniversitesi Fen Bilimleri Enstitüsü, Ankara.
- Canyurt, O.E., Öztürk, H.K., Hepbasli, A. and Utlu, Z.**, 2005. Estimating the Turkish residential–commercial energy output based on genetic algorithm (GA) approaches, *Energy Policy*, **33**, 1011–1019.
- Canyurt, O.E. and Öztürk, H.K.**, 2006. Three different applications of genetic algorithm (GA) search techniques on oil demand estimation, *Energy Conversion and Management*, **47**, 3138–3148.
- Castillo, P.A., Merelo, J.J., Prieto, A., Rivas, V. and Romero, G.**, 2000. G-Prop: Global optimization of multilayer perceptrons using GAs, *Neurocomputing*, **35**, 149-163.
- Ceylan, H. and Öztürk, H.K.**, 2004. Estimating energy demand of Turkey based on economic indicators using genetic algorithm approach, *Energy Conversion and Management*, **45**, 2525–2537.
- Deb, K.**, 2001. Multi-Objective Optimization using Evolutionary Algorithms, John Wiley & Sons, England.
- DEK-TMK (Dünya Enerji Konseyi Türk Milli Komitesi)**, 2004. 2003-2004 Türkiye Enerji Raporu, Ankara, Türkiye.
- DEK-TMK (Dünya Enerji Konseyi Türk Milli Komitesi)**, 2006. Dünya ve Türkiye Enerji İstatistikleri, Ankara, Türkiye.
- Demirbaş, A.**, 2002. Turkey’s energy overview beginning in the twenty-first century, *Energy Conversion and Management*, **43**, 1877-1887.

- Doganis, P., Alexandridis, A., Patrinos, P. and Sarimveis, H.,** 2006. Time series sales forecasting for short shelf-life food products based on artificial neural networks and evolutionary computing, *Journal of Food Engineering*, **75**, 196-204.
- Durmayaz, A., Kadioğlu, M. and Şen, Z.,** 2000. An application of the degree-hours method to estimate the residential heating energy requirement and fuel consumption in Istanbul, *Energy*, **25**, 1245-1256.
- Ediger, V.Ş. and Kentel, E.,** 1999. Renewable energy potential as an alternative to fossil fuels in Turkey, *Energy Conversion and Management*, **40**, 743-755.
- Ediger, V.Ş. and Tatlıdil, H.,** 2002. Forecasting the primary energy demand in Turkey and analysis of cyclic patterns, *Energy Conversion and Management*, **43**, 473-487.
- Ediger, V.Ş. and Huvaz, Ö.,** 2006. Examining the sectoral energy use in Turkish economy (1980-2000) with the help of decomposition analysis, *Energy Conversion and Management*, **47**, 732-745.
- Ediger, V.Ş., Sertaç, A. and Uğurlu, B.,** 2006. Forecasting production of fossil fuel sources in Turkey using a comparative regression and ARIMA model, *Energy Policy*, **34**, 3836-3846.
- Ediger, V.Ş. and Akar, S.,** 2007. ARIMA forecasting of primary energy demand by fuel in Turkey, *Energy Policy*, **35**, 1701-1708.
- Engin, O.,** 2001. Akış Tipi Çizelgeleme Problemlerinin Genetik Algortima İle Çözüm Performansının Arttırılmasında Parametre Optimizasyonu, *Doktora Tezi*, İTÜ Fen Bilimleri Enstitüsü, İstanbul.
- Ermis, K., Midilli, A., Dincer, I. and Rosen, M.A.,** 2007. Artificial neural network analysis of world green energy use, *Energy Policy*, **35**, 1731-1743.
- Eroğlu, V.,** 2006. Hydroelectric energy demand and consumption, *Devlet Su İşleri Raporu*.
- ETKB (Enerji ve Tabii Kaynaklar Bakanlığı),** 2004. Türkiye Uzun Dönem Elektrik Enerjisi Talep Çalışması Raporu, Ankara, Türkiye.
- Ferentinos, K.P.,** 2005. Biological engineering applications of feedforward neural networks designed and parameterized by genetic algorithms, *Neural Networks*, **18**, 934-950.
- Fish, K.E., Johnson, J.D., Dorsey, R.E. and Blodgett, J.G.,** 2004. Using an artificial neural network trained with a genetic algorithm to model brand share, *Journal of Business Research*, **57**, 79-85.
- Fu, L.,** 1994. Neural Networks In Computer Intelligence, McGraw-Hill, United States of America.
- Gen, M. and Cheng, R.,** 1997. Genetic Algorithms and Engineering Design, John Wiley & Sons, Inc., New York.
- Goldberg, D.E.,** 1989. Genetic Algorithms in Search, Optimization, and Machine Learning, Addison Wesley Publishing Company, USA.
- Görücü, F.B. and Gümrah, F.,** 2004. Evaluation and Forecasting of Gas Consumption by Statistical Analysis, *Energy Sources*, **26**, 267-276.

- Görücü, F.B., Geris, P.U. and Gümrah, F.,** 2004. Artificial Neural Network Modeling for Forecasting Gas Consumption, *Energy Sources*, **26**, 299-307.
- Gupta, J.N.D. and Sexton R.S.,** 1999, Comparing backpropagation with a genetic algorithm for neural network training, *Omega*, **27**, 679-684.
- Haldenbilen, S. and Ceylan, H.,** 2005. Genetic algorithm approach to estimate transport energy demand in Turkey, *Energy Policy*, **33**, 89-98.
- Haykin, S.,** 1999. Neural Networks: A Comprehensive Foundation, Prentice-Hall, New Jersey.
- Herrera, F. and Verdegay, J.L.,** 1996. Genetic Algorithms and Soft Computing, Physica-Verlag Heidelberg, Italy.
- Kalogirou, S.A.,** 2001. Artificial neural networks in renewable energy systems applications: a review, *Renewable and Sustainable Energy Reviews*, **5**, 373-401.
- Kermanshahi, B. and Iwamiya, H.,** 2002, Up to year 2020 load forecasting using neural nets, *Electrical Power and Energy Systems*, **24**, 789-797.
- Kim, B. and Bae, J.,** 2005. Prediction of plasma processes using neural network and genetic algorithms, *Solid-State Electronics*, **49**, 1576-1580.
- Kuo, R.J.,** 2001. A sales forecasting system based on fuzzy neural network with initial weights generated by genetic algorithm, *European Journal of Operational Research*, **129**, 496-517.
- Man, K.F., Tang, K.S. and Kwong, S.,** 1999. Genetic Algorithms, Springer-Verlag, London.
- Midilli, A., Dincer, I. and Ay, M.,** 2006, Green energy strategies for sustainable development, *Energy Policy*, **34**, 3626-3633.
- Munoz, J.R. and David, J.S.,** 1998. A modelling methodology for assessing the impact of climate variability and climatic change on hydroelectric generation, *Energy Conversion and Management*, **39**, 1459-1469.
- Murat, Y.S. and Ceylan, H.,** 2006. Use of artificial neural networks for transport energy demand modeling, *Energy Policy*, **34**, 3165–3172.
- Niska, H., Hiltunen, T., Karppinen, A., Ruuskanen, J. and Kolehmainen, M.,** 2004. Evolving the neural network model for forecasting air pollution time series, *Engineering Applications of Artificial Intelligence*, **17**, 159-167.
- Öztürk, H.K., Ceylan, H., Hepbasli, A. and Utlu, Z.,** 2004. Estimating petroleum exergy production and consumption using vehicle ownership and GDP based on genetic algorithm approach, *Renewable and Sustainable Energy Reviews*, **8**, 289-302.
- Öztürk, H.K., Ceylan, H., Canyurt, O.E. and Hepbasli, A.,** 2005. Electricity estimation using genetic algorithm approach: a case study of Turkey, *Energy*, **30**, 1003-1012.
- Porto, V.W., Fogel, D.B. and Fogel L.J.,** 1995, Alternative neural network training methods, *IEEE*, **10**, 16-22.
- Rooij, A.J.F., Jain, L.C. and Johnson, R.P.,** 1996, Neural Network Training Using Genetic Algorithms, World Scientific Publishing Co. Pte. Ltd., Singapore.

- Sarak, H. and Satman, A.,** 2003. The degree-day method to estimate the residential heating natural gas consumption in Turkey: a case study, *Energy*, **28**, 929-939.
- Schaffer, J.D., Whitley, D. and Eshelman, L.J.,** 1992, Combinations of genetic algorithms and neural networks: A survey of the state of the art, *IEEE*, **5**, 1-37.
- Sexton, R.S., Dorsey, R.E. and Johnson, J.D.,** 1999, Optimization of neural networks: A comparative analysis of the genetic algorithm and simulated annealing, *European Journal of Operational Research*, **114**, 589-601.
- Sexton, R.S. and Gupta, J.N.D.,** 2000. Comparative evaluation of genetic algorithm and backpropagation for training neural networks, *Information Sciences*, **129**, 45-59.
- Sexton, R.S., Dorsey, R.E. and Sikander, N.A.,** 2004, Simultaneous optimization of neural network function and architecture algorithm, *Decision Support Systems*, **36**, 283-296.
- Sözen, A., Arcaklıoğlu, E., Ozalp, M. and Caglar, N.,** 2005-a, Forecasting based on neural network approach of solar potential in Turkey, *Renewable Energy*, **30**, 1075-1090.
- Sözen, A., Arcaklıoğlu, E., and Ozkaymak, M.,** 2005-b, Turkey's net energy consumption, *Applied Energy*, **81**, 209-221.
- Şahin, Ş.Ö.,** 2002. Yapay sinir ağları yardımı ile dinamik bir senaryo analizi, *Doktora Tezi*, İTÜ Fen Bilimleri Enstitüsü, İstanbul.
- Şahin, Ş.Ö., Ülengin, F. and Ülengin, B.,** 2004. Using neural networks and cognitive mapping in scenario analysis: The case of Turkey's inflation dynamics, *European Journal of Operational Research*, **158**, 124-145.
- TMMOB Makina mühendisleri odası,** 2005. Enerji politikaları; yerli, yeni ve yenilenebilir enerji kaynakları, *TMMOB 5. Enerji Sempozyumu Bildiriler Kitabı*, Ankara, Türkiye.
- Toksarı, M.D.,** 2007, Ant colony optimization approach to estimate energy demand of Turkey, *Energy Policy*, doi:10.1016/j.enpol.2007.01.028.
- Topçu, Y.İ. and Ülengin, F.,** 2004. Energy for the future: An integrated decision aid for the case of Turkey, *Energy*, **29**, 137-154.
- TÜSİAD (Türk Sanayicileri ve İşadamları Derneği),** 1998. 21. Yüzyıla Girerken Türkiye'nin Enerji Stratejisinin Belirlenmesi, Rapor.
- Utgikar, V.P. and Scott, J.P.,** 2006, Energy forecasting: Predictions, reality and analysis of causes of error, *Energy Policy*, **34**, 3087-3092.
- Ünsal, İ. ve Önöz, B.,** 2006. Hidrolik kaynaklarımızın değerlendirilmesi, İTÜ Enerji Çalıştay ve Sergisi, İstanbul.
- Vlahogianni, E., Karlaftis, M.G. and Golias J.C.,** 2005. Optimized and meta-optimized neural networks for short-term traffic flow prediction: A genetic approach, *Transportation Research Part C*, **13**, 211-234.
- Wang, T. and Huang, C.,** 2007. Applying optimized BPN to a chaotic time series problem, *Expert Systems with Applications*, **32**, 193-200.

- Welstead, S.T.**, 1994. Neural Networks and Fuzzy Logic Applications in C/C++, John Wiley & Sons, Canada.
- Yi-Hui, L.**, 2007. Evolutionary neural network modeling for forecasting the field failure data of repairable systems, *Expert Systems with Applications*, **33**, 1090-1096.
- Yüksek, O., Kömürcü, M.I., Yüksel, I. and Kaygusuz K.**, 2006. The role of hydropower in meeting Turkey's electric energy demand, *Energy Policy*, **34**, 3093-3103.
- Yumurtacı, Z. and Asmaz, E.**, 2004. Electric Energy Demand of Turkey for the Year 2050, *Energy Sources*, **26**, 1157-1164.

EKLER

EK_A

ÖNERİLEN MODELİN MATLAB KODLARI

Kromozom oluşturan fonksiyon

```
function kromozom=kromozom_yarat(ninput,noutput,nmax,wmax)
% ninput: girdi nöron sayısı
% noutput: çıktı nöron sayısı
% nmax: maksimum gizli nöron sayısı
% wmax: başlangıç ağırlıklarının alabileceği üst sınır değeri

n=randint(1,1,[1,nmax]);
kromozom=zeros(1,2+n*(ninput+noutput));

% Bir kromozom 2+n*(ninput+noutput) adet genden oluşur. Populasyon
% oluşturulurken en uzun kromozoma göre oluşturulacak. 2+n*(ninput+noutput)
% uzunluğundaki genin geri kalan bölümü 0 değerini alacak.

kromozom(1)=n; %ilk gen gizli nöron sayısını temsil eder.
kromozom(2:end-1)=wmax*(rand(1,n*(ninput+noutput))-0.5);

%2. gen ile sondan 1 önceki gen arası başlangıç ağırlıklarını temsil eder.

kromozom(end)=rand(1); %son gen öğrenme oranını temsil eder.
end
return
```

Başlangıç popülasyonunu oluşturan fonksiyon

```
function Population = creation(GenomeLength, FitnessFcn, options)
global nmax wmax ninput noutput

maxkrolength=2+nmax*(ninput+noutput); % maksimum kromozom uzunluğu
nk=options.PopulationSize; % populasyon büyüklüğü
Population=zeros(nk,maxkrolength); % (nk*maxkrolength) boyutunda
% populasyon vektörü

% Başlangıç popülasyonu oluşturulur.
for i=1:nk
    tk=kromozom_yarat(ninput,noutput,nmax,wmax);
    Population(i,1:length(tk))=tk;
end
return
```

Uygunluk fonksiyonunda kullanılan YSA

```
function [error]=my_neural (n,lrate,W1,W2)
% n: Gizli katmandaki gizli nöron sayısı
% lrate: öğrenme oranı
% W1: girdi ile gizli nöronlar arasındaki başlangıç ağırlıkları
% W2: gizli ile çıktı nöronları arasındaki başlangıç ağırlıkları
% xt: eğitimde kullanılacak x değişkeni
% yt: eğitimde kullanılacak y değişkeni
% xv: geçerlemede kullanılacak x değişkeni
% yv: geçerlemede kullanılacak y değişkeni
global xt yt xv yv ninput noutput
% Eğitim için kullanılan x ve y'yi normalize edilir
[xtn,minxt,maxxt,ytn,minyt,maxyt] = premnmx(xt,yt);
% gerçekleştirme için kullanılan x'i normalize edilir
[xvn,minxv,maxxv] = premnmx(xv);
% Ağ oluşturulur
net=newff(minmax(xtn),[n,noutput]);
net.trainParam.show = NaN;
net.trainParam.epochs = 100;
net.trainParam.goal = 1e-5;
net.trainParam.lr = lrate;
% girdi ile gizli nöronlar arasındaki başlangıç ağırlıkları W1 olarak,
% gizli ile çıktı nöronlar arasındaki başlangıç ağırlıkları da W2 olarak,
% ağa girilir
net.IW{1}=W1;
net.LW{2,1}=W2;
[net,ytr]=train(net,xtn,ytn); % Ağ eğitilir
yen = sim(net,xvn); %normalize edilmiş y tahmin değerleri bulur
ye = postmnmx(yen,minyt,maxyt); %normalize edilen değeri gerçek değerine
% çevirir.
% min ve max değerini eğitim setindeki y'nin min max değeri olarak alır.
error=sqrt((sum((yv-ye).^2))/sum(yv.^2)); % görelî hata (relative error)
return
```

Uygunluk fonksiyonu

```
function fitnessfun = my_fitness(kro)
global xt yt xv yv ninput noutput

% Kromozom oluşturulur. İlk gen gizli nöron sayısı, son gen öğrenme oranı,
% aradaki genler ise başlangıç ağırlıklarıdır.
n = kro(1);

W1 = reshape(kro(2:1+n*ninput), n, ninput);
W2 = reshape(kro(2+n*ninput:1+n*(ninput+noutput)), noutput, n);
lrate = kro(2+n*(ninput+noutput));
fitnessfun = my_neural(n,lrate,W1,W2);
return
```

Çaprazlama fonksiyonu

```
function crossover = my_crossover(parents, options, nvars, FitnessFcn, ...
    unused,thisPopulation)
global ninput noutput
% Çaprazlama operatöründe sadece ağırlıklarda çaprazlama yapılır.
% İki kromozomun nöronları birbirleriyle yer değiştirerek çaprazlama
% gerçekleştirilir. Yer değiştirecek nöronlar rassal belirlenir.
nparent = length(parents);
crossover=zeros(nparent, size(thisPopulation,2));
for icr = 0:nparent/2-1
    % İlk ebeveynin başlangıç ağırlıkları matris haline getirilir.
    nn1=thisPopulation(parents(2*icr + 1),1);
    IW1=reshape(thisPopulation(parents(2*icr + 1),2:ninput*nn1+1),nn1,ninput);
    LW1=reshape(thisPopulation(parents(2*icr + 1),(ninput*nn1+2:nn1* ...
(ninput+noutput)+1)), noutput, nn1);
    % İkinci ebeveynin başlangıç ağırlıkları matris haline getirilir.
    nn2=thisPopulation(parents(2*icr + 2),1);
    IW2=reshape(thisPopulation(parents(2*icr + 2),2:ninput*nn2+1),nn2,ninput);
    LW2=reshape(thisPopulation(parents(2*icr + 2),(ninput*nn2+2:nn2* ...
(ninput+noutput)+1)), noutput, nn2);
    % Ebeveynlerin hangi nöronlarının yer değiştireceğine karar verilir.
    rsira1=randperm(nn1);
    rsira2=randperm(nn2);
    rassal=randint(1,1,[1,min(nn1,nn2)]);
    % tempIW (geçici bir IW matrisi) ve tempLW (geçici bir LW matrisi)
    % oluşturulur. tempIW ve tempLW birinci ebeveyninden seçilen nöronların
    % oluşturduğu IW ve LW vektörlerinden oluşur
    tempIW=IW1(rsira1(1:rassal),:);
    tempLW=LW1(:,rsira1(1:rassal));
    % Birinci ebeveyninden seçilen nöronların oluşturduğu IW yerine ikinci
    % ebeveyninden seçilen nöronların oluşturduğu IW vektörü getirilir.
    IW1(rsira1(1:rassal),:)=IW2(rsira2(1:rassal),:);
    % İkinci ebeveynde seçilen nöronların yerine birinci ebeveyninden seçilen
    % nöronlar getirilir.
    IW2(rsira2(1:rassal),:)=tempIW;
    % Aynı işlem LW içinde yapılır.
    LW1(:,rsira1(1:rassal))=LW2(:,rsira2(1:rassal));
    LW2(:,rsira2(1:rassal))=tempLW;    % Nöronların birbirleriyle yer değiştirmesi
                                        % tamamlandı
                                        % Matris halindeki başlangıç ağırlıkları
                                        % vektör haline getirilerek
                                        % kromozom oluşturulur.
    crossover(2*icr + 1,1:2+nn1*(ninput+noutput))=[nn1 IW1(:)' LW1(:)' ...
        thisPopulation(parents(2*icr + 1),2+nn1*(ninput+noutput))];
    crossover(2*icr + 2,1:2+nn2*(ninput+noutput))=[nn2 IW2(:)' LW2(:)' ...
        thisPopulation(parents(2*icr + 2),2+nn2*(ninput+noutput))];
return
```

Mutasyon fonksiyonu

```
function mutation = my_mutation(parents, options, nvars, ...
    FitnessFcn, state, thisScore, thisPopulation)
% parents: Ebeveynlerin indisleri
% thisPopulation: Ebeveynlerin oluşturduğu populasyon
global nmax wmax ninput noutput
nmk=length(parents);
mutation = zeros(nmk,nvars);
for i=1:nmk
    indmk = parents(i);
    rs1=rand(1);
    if rs1<1/3 % rassal sayı 1/3'ten küçükse nöron sayısı mutasyona uğrar
        neski=thisPopulation(indmk,1);
        mutation(i,1)=randint(1,1,[1,nmax]);
        if mutation(i,1)>neski % mutasyon sonucu gelen yeni nöron sayısı
            % eskisinden büyükse kromozoma yeni nöron
            % eklenir. Eklenen kromozomların
            % ağırlıkları rassal belirlenir.
            mutation(i,:) = mutadd(thisPopulation(indmk,:),...
                mutation(i,1)-neski,neski); % Nöron ekleme fonksiyonu

        elseif mutation(i,1)<neski % mutasyon sonucu gelen yeni nöron
            % sayısı eskisinden büyükse kromozomdan
            % nöron çıkarılır. Çıkarılan nöronlar
            % rassal belirlenir.
            mutation(i,:) = mutsub (thisPopulation(indmk,:),...
                neski-mutation(i,1),neski); % Nöron çıkarma fonksiyonu
        else
            mutation(i,:) = thisPopulation(indmk,:);
        end

    elseif rs1<2/3 % rassal sayı 1/3 ile 2/3 arasındaysa başlangıç
        % ağırlıkları mutasyona uğrar
        mutation(i,:)=thisPopulation(indmk,:);
        % Mutasyona uğrayacak olan ağırlık da rassal belirlenir.
        indw=randint(1,1,[2,muation(i,1)*(ninput+noutput)+1]);
        % Mutasyona uğrayacak olan ağırlığa ortalaması 0 varyansı 1 olan
        % bir rassal sayı eklenerek mutasyona uğratılır.
        mutation(i,indw)=mutation(i,indw)+randn(1);
    else % rassal sayı 2/3 ile 1 arasındaysa öğrenme oranı
        % mutasyona uğrar
        mutation(i,:)=thisPopulation(indmk,:);
        % öğrenme oranının olduğu gene 0 ile 1 arasında yeni bir rassal
        % sayı gelir
        mutation(i,muation(i,1)*(ninput+noutput)+2)=rand(1);
    end
end
return
```

Mutasyon-ekleme fonksiyonu

```
function mutation_add = mutadd (kro,naddition,neski)
% Yeni nöron eklemek için kullanılan operatör.
% Mutasyonda yeni nöron eklenirse bu operatör kullanılıyor.
% Yeni nöronların ağırlıkları rassal olarak belirleniyor.
global nmax wmax ninput noutput
nny=neski+naddition; %yeni nöron sayısı
yeniuzunluk=2+nny*(ninput+noutput); %kromozomun yeni uzunluğu
eskiuzunluk=2+neski*(ninput+noutput); % kromozomun mutasyona
% uğramadan önceki uzunluğu

mutation_add=zeros(1,length(kro));

mutation_add(yeniuzunluk)=kro(eskiuzunluk); % learning rate'i yeni yerine
% kaydırılır
mutation_add(yeniuzunluk-(naddition*noutput):yeniuzunluk-1)=...
wmax*(rand(1,naddition*noutput)-0.5); % yeni nöronların gizli ve
% çıktı nöronları arasındaki
% ağırlıkları rassal olarak
% belirlenir ve kromozom
% üzerindeki yerine
% yerleştirilir
mutation_add(2+nny*ninput:yeniuzunluk-(naddition*noutput)-1)=...
kro(2+neski*ninput:eskiuzunluk-1); % eski kromozomdaki gizli
% ve çıktı nöronları
% arasındaki ağırlıklar yeni
% yerine kaydırılır
mutation_add(2+neski*ninput:2+nny*ninput-1)=...
wmax*(rand(1,naddition*ninput)-0.5); % yeni nöronların girdi ve
% gizli nöronları arasındaki
% ağırlıkları rassal olarak
% belirlenir ve kromozom
% üzerindeki yerine
% yerleştirilir
mutation_add(2:neski*ninput+1)=kro(2:neski*ninput+1);
% eski kromozomdaki gizli
% ve çıktı nöronları
% arasındaki ağırlıklar yeni
% yerine kaydırılır
mutation_add(1)=nny; % yeni kromozomun yeni gizli
% nöron sayısı ilk gene
% yerleşir.

return
```

Mutasyon-çıkarma fonksiyonu

```
function mutation_sub= mutsub (kro,nsub,neski)
% Nöron çıkartma operatörü.
% Mutasyon sırasında nöron sayısını gösteren ilk gen mutasyona uğrarsa ve
% nöron sayısı eskisinden az olursa bu operatör kullanılıyor.
% Ağdan çıkacak olan nöronların ağırlıkları rassal olarak belirleniyor.
global nmax wmax ninput noutput
nny=neski-nsub;
yeniuzunluk=2+nny*(ninput+noutput); % Kromozomun yeni uzunluğu
eskiuzunluk=2+neski*(ninput+noutput); % Kromozomun eski uzunluğu
% Mutasyon sonucu oluşacak kromozomun toplam uzunluğu eski uzunluğunun
% aynısı olacak
mutation_sub=zeros(1,length(kro));

% Yeni kromozomun son geni (0'lardan önceki) öğrenme oranına eşit
% olacak
mutation_sub(yeniuzunluk)=kro(eskiuzunluk);
% IW: girdi ve gizli nöronlar arasındaki ağırlıklar
% LW: gizli ve çıktı nöronları arasındaki ağırlıklar
% IW ve LW dizi formundayken, matris formuna getirilir
IW=reshape(kro(2:ninput*neski+1),ninput,neski);
LW=reshape(kro(ninput*neski+2:neski*(ninput+noutput)+1), neski,noutput);
% eski kromozom uzunluğunda rassal bir sıra atılır
rsira=randperm(neski);
% nsub adet nöron çıkartmak için çıkartılacak nöronların indisleri
% belirlenir.
indcik=rsira(1:nsub);
% IW ve LW matrislerinde çıkartılacak nöronların yerine 0 gelir

% IW(indcik,:)=[];
% LW(:,indcik)=[];
IW(:,indcik)=[];
LW(indcik,:)=[];
% Yeni oluşan kromozom tekrar dizi formuna getirilir.
tempk=nny;
tempk=[tempk IW(:)' LW(:)'];
mutation_sub(1:yeniuzunluk-1)=tempk;
return
```

EK_B**Tablo B.1: Çalışmada Kullanılan Veriler**

Yıllar	Hidroelektrik üretimi (GWh)	Birincil Enerji İthalatı (TEP)	GSYH (milyar \$)	Kurulu güç (MW)	Elektrik Tüketimi (GWh)	Enerji Tüketimi (Bin TEP)	Nüfus (Bin)
1970	3033	4642	533	2235	7310	18872	34391
1971	2610	6375	465	2578	8290	20088	35470
1972	3204	8649	574	2711	9530	22411	36550
1973	2603	9969	705	3192	10530	24512	37629
1974	3356	11020	948	3732	11360	25535	38709
1975	5904	11119	1155	4187	13490	27437	39789
1976	8375	13988	1295	4364	16080	29695	40868
1977	8572	15450	1451	4727	17970	32454	41948
1978	9335	15609	1554	4869	18930	32571	43027
1979	10289	13049	1860	5119	19630	30708	44107
1980	11348	15031	1518	5119	20400	31973	45186
1981	12616	15069	1546	5538	22030	32049	46266
1982	14167	16777	1360	6639	23590	34388	47346
1983	11172	17726	1261	6935	24470	35697	48425
1984	13426	19030	1195	8459	27640	37425	49505
1985	12045	19410	1320	9119	29710	39399	50584
1986	11873	21002	1459	10113	32210	42472	51664
1987	18618	25463	1629	12493	36700	46883	52743
1988	28950	28488	1685	14518	39720	47910	53823
1989	17940	27015	1933	15806	43120	50705	54903
1990	23148	30936	2655	16315	46820	52987	55982
1991	22683	29597	2603	17207	49280	54278	57062
1992	26568	31487	2682	18714	53980	56684	58141
1993	33951	36180	2981	20335	59240	60265	59221
1994	30586	35344	2173	20857	61400	59127	60300
1995	35541	39779	2727	20952	67390	63679	61380
1996	40475	44332	2888	21247	74160	69862	62460
1997	39816	47519	3021	21889	81880	73779	63539
1998	42229	48632	3176	23352	87700	74709	64619
1999	34678	49406	2847	26117	91200	74275	65698
2000	30879	56342	2941	27264	98300	80500	66778
2001	24010	52780	2146	28332	97070	75402	67858
2002	33684	58629	2622	31846	102950	78331	68937
2003	35330	65239	3412	35587	111770	83826	70017
2004	46084	67885	4187	36824	121140	87818	71096

EK_C

Tablo C.1: Hidroelektrik üretimi tahmini için önerilen model ile bulunan sonuçlar

Devir Sayısı	Uygunluk Değeri	n	w_{11}	w_{12}	w_{13}	w_{14}	w_{15}	w_{21}	w_{22}	w_{23}	w_{24}	w_{25}	w_{31}	w_{32}	w_{33}
1	0,3912	3	0,0007	0,0012	0,0007	-0,0006	-0,0018	-0,0006	-0,0044	-0,0020	-0,0044	-0,0008	0,0041	-0,0008	0,0047
2	0,4031	3	0,0035	-0,0011	-0,0011	0,0035	0,0028	-0,0027	-0,0033	0,0040	0,0011	-0,0047	0,0007	-0,0022	0,0030
3	0,4011	3	0,0032	0,0032	0,0000	-0,0021	-0,0021	0,0000	-0,0004	-0,0004	0,0000	-0,0046	-0,0046	0,0000	0,0018
4	0,4031	3	-0,0022	-0,0016	-0,0016	-0,0031	-0,0007	-0,0007	-0,0035	-0,0013	-0,0013	0,0016	-0,0036	-0,0036	-0,0025
5	0,4031	3	0,0036	0,0036	-0,0022	-0,0012	-0,0012	0,0022	0,0044	0,0044	0,0028	0,0031	0,0031	-0,0044	-0,0035
6	0,4031	3	0,0035	-0,0011	-0,0011	0,0035	0,0028	-0,0027	-0,0033	0,0040	0,0011	-0,0047	0,0007	-0,0022	0,0030
7	0,4011	3	0,0032	0,0032	0,0000	-0,0021	-0,0021	0,0000	-0,0004	-0,0004	0,0000	-0,0046	-0,0046	0,0000	0,0018
8	0,4031	3	-0,0022	-0,0016	-0,0016	-0,0031	-0,0007	-0,0007	-0,0035	-0,0013	-0,0013	0,0016	-0,0036	-0,0036	-0,0025
9	0,4031	3	0,0036	0,0036	-0,0022	-0,0012	-0,0012	0,0022	0,0044	0,0044	0,0028	0,0031	0,0031	-0,0044	-0,0035
10	0,4031	3	0,0037	-0,0037	-0,0037	-0,0003	-0,0026	-0,0026	0,0020	0,0038	0,0038	0,0011	0,0040	0,0040	0,0043
11	0,4031	3	0,0035	-0,0011	-0,0011	0,0035	0,0028	-0,0027	-0,0033	0,0040	0,0011	-0,0047	0,0007	-0,0022	0,0030
12	0,4011	3	0,0032	0,0032	0,0000	-0,0021	-0,0021	0,0000	-0,0004	-0,0004	0,0000	-0,0046	-0,0046	0,0000	0,0018
13	0,4031	3	-0,0022	-0,0016	-0,0016	-0,0031	-0,0007	-0,0007	-0,0035	-0,0013	-0,0013	0,0016	-0,0036	-0,0036	-0,0025
14	0,4031	3	0,0036	0,0036	-0,0022	-0,0012	-0,0012	0,0022	0,0044	0,0044	0,0028	0,0031	0,0031	-0,0044	-0,0035
15	0,4031	3	0,0037	-0,0037	-0,0037	-0,0003	-0,0026	-0,0026	0,0020	0,0038	0,0038	0,0011	0,0040	0,0040	0,0043
16	0,4031	3	0,0035	-0,0011	-0,0011	0,0035	0,0028	-0,0027	-0,0033	0,0040	0,0011	-0,0047	0,0007	-0,0022	0,0030
17	0,4011	3	0,0032	0,0032	0,0000	-0,0021	-0,0021	0,0000	-0,0004	-0,0004	0,0000	-0,0046	-0,0046	0,0000	0,0018
18	0,4031	3	-0,0022	-0,0016	-0,0016	-0,0031	-0,0007	-0,0007	-0,0035	-0,0013	-0,0013	0,0016	-0,0036	-0,0036	-0,0025
19	0,4031	3	0,0036	0,0036	-0,0022	-0,0012	-0,0012	0,0022	0,0044	0,0044	0,0028	0,0031	0,0031	-0,0044	-0,0035
20	0,4031	3	0,0035	-0,0011	-0,0011	0,0035	0,0028	-0,0027	-0,0033	0,0040	0,0011	-0,0047	0,0007	-0,0022	0,0030
21	0,4011	3	0,0032	0,0032	0,0000	-0,0021	-0,0021	0,0000	-0,0004	-0,0004	0,0000	-0,0046	-0,0046	0,0000	0,0018
22	0,4031	3	-0,0022	-0,0016	-0,0016	-0,0031	-0,0007	-0,0007	-0,0035	-0,0013	-0,0013	0,0016	-0,0036	-0,0036	-0,0025
23	0,4031	3	0,0035	-0,0011	-0,0011	0,0035	0,0028	-0,0027	-0,0033	0,0040	0,0011	-0,0047	0,0007	-0,0022	0,0030
24	0,4031	3	0,0035	-0,0011	-0,0011	0,0035	0,0028	-0,0027	-0,0033	0,0040	0,0011	-0,0047	0,0007	-0,0022	0,0030
25	0,4011	3	0,0032	0,0032	0,0000	-0,0021	-0,0021	0,0000	-0,0004	-0,0004	0,0000	-0,0046	-0,0046	0,0000	0,0018
26	0,4031	3	-0,0022	-0,0016	-0,0016	-0,0031	-0,0007	-0,0007	-0,0035	-0,0013	-0,0013	0,0016	-0,0036	-0,0036	-0,0025
27	0,4031	3	0,0036	0,0036	-0,0022	-0,0012	-0,0012	0,0022	0,0044	0,0044	0,0028	0,0031	0,0031	-0,0044	-0,0035
28	0,4031	3	0,0035	-0,0011	-0,0011	0,0035	0,0028	-0,0027	-0,0033	0,0040	0,0011	-0,0047	0,0007	-0,0022	0,0030
29	0,4011	3	0,0032	0,0032	0,0000	-0,0021	-0,0021	0,0000	-0,0004	-0,0004	0,0000	-0,0046	-0,0046	0,0000	0,0018
30	0,4031	3	-0,0022	-0,0016	-0,0016	-0,0031	-0,0007	-0,0007	-0,0035	-0,0013	-0,0013	0,0016	-0,0036	-0,0036	-0,0025

Tablo C.1: (devamı)

Devir Sayısı	w_{34}	w_{35}	v_{11}	v_{12}	v_{13}	Öğrenme Oranı
1	0,0040	0,0047	-0,0033	0,0001	-0,0033	0,0882
2	0,0016	-0,0041	0,0001	-0,0049	0,0048	0,5672
3	0,0018	0,0000	0,2513	0,0045	0,0000	0,5771
4	-0,0011	-0,0011	0,0029	0,0012	0,0012	0,7940
5	-0,0035	0,0033	-0,0016	-0,0016	0,0000	0,2785
6	0,0016	-0,0041	0,0001	-0,0049	0,0048	0,5672
7	0,0018	0,0000	0,2513	0,0045	0,0000	0,5771
8	-0,0011	-0,0011	0,0029	0,0012	0,0012	0,7940
9	-0,0035	0,0033	-0,0016	-0,0016	0,0000	0,2785
10	-0,0043	-0,0043	-0,0039	0,0045	0,0045	0,1994
11	0,0016	-0,0041	0,0001	-0,0049	0,0048	0,5672
12	0,0018	0,0000	0,2513	0,0045	0,0000	0,5771
13	-0,0011	-0,0011	0,0029	0,0012	0,0012	0,7940
14	-0,0035	0,0033	-0,0016	-0,0016	0,0000	0,2785
15	-0,0043	-0,0043	-0,0039	0,0045	0,0045	0,1994
16	0,0016	-0,0041	0,0001	-0,0049	0,0048	0,5672
17	0,0018	0,0000	0,2513	0,0045	0,0000	0,5771
18	-0,0011	-0,0011	0,0029	0,0012	0,0012	0,7940
19	-0,0035	0,0033	-0,0016	-0,0016	0,0000	0,2785
20	0,0016	-0,0041	0,0001	-0,0049	0,0048	0,5672
21	0,0018	0,0000	0,2513	0,0045	0,0000	0,5771
22	-0,0011	-0,0011	0,0029	0,0012	0,0012	0,7940
23	0,0016	-0,0041	0,0001	-0,0049	0,0048	0,5672
24	0,0016	-0,0041	0,0001	-0,0049	0,0048	0,5672
25	0,0018	0,0000	0,2513	0,0045	0,0000	0,5771
26	-0,0011	-0,0011	0,0029	0,0012	0,0012	0,7940
27	-0,0035	0,0033	-0,0016	-0,0016	0,0000	0,2785
28	0,0016	-0,0041	0,0001	-0,0049	0,0048	0,5672
29	0,0018	0,0000	0,2513	0,0045	0,0000	0,5771
30	-0,0011	-0,0011	0,0029	0,0012	0,0012	0,7940

EK_D

Tablo D.1: Enerji ithalatı tahmini için önerilen model ile bulunan sonuçlar

Devir Sayısı	Uygunluk Değeri	<i>n</i>	Ağırlık															
1	0,2628	5	-0,0016	0,0032	-0,0043	1,0372	-0,9018	0,002	-0,0012	-0,0008	-0,0038	-0,0027	-0,0025	-0,0036	-0,0017	0,1118	-0,0004	
2	0,276	5	-0,0021	0,0001	0,0013	0,0011	0,0027	0,1127	0,0037	0,0031	0,0011	-0,0024	-0,0001	-0,0001	0,0026	0,2808	-0,2524	
3	0,3727	5	0,0042	-0,0022	-0,0022	0,0030	1,1094	-0,0046	-0,0003	-0,0038	-0,0046	0,0027	0,001	-0,0836	-0,0836	-0,002	-0,0013	
4	0,3016	6	-0,0038	0,0024	-0,0019	-0,3863	0,0034	-0,8643	-0,0009	-0,0038	0,0002	0,0002	-0,002	-0,0017	-0,0037	-0,0048	0,3888	
5	0,3508	6	0,5606	0,6977	-0,0023	-0,0036	0,0046	0,0016	-0,0021	-0,0023	-0,0022	0,0005	0,0047	0,0023	0,0013	-0,0021	-0,0007	
6	0,2252	7	-0,004	0,0013	0,0016	0,0023	-0,0006	-0,0047	-0,4897	-0,0029	0,002	-0,0042	0,0003	-0,0011	-0,0011	-0,0011	0,0025	
7	0,3312	8	0,0037	0,0023	0,0007	-0,0019	0,0041	1,1158	-0,0038	-0,0031	0,0034	-0,0013	-0,0007	-0,0036	-3,0261	-0,0041	-0,0033	
8	0,348	8	0,0007	0,0007	-0,0021	-0,8486	0,0045	0,0007	0,0007	0,0044	-0,0009	0,0022	0,0011	-0,0033	-0,0037	-0,0009	-0,0009	
9	0,3024	9	0,0013	-0,0002	0,0032	-0,0002	0,0041	-0,0002	-0,0002	0,0041	0,2709	-0,0012	-0,0005	0,0048	0,0041	-0,0002	0,0041	
10	0,2252	10	-0,0003	-0,0014	0,0027	-0,0038	1,1983	-0,0049	-0,0049	-0,0049	-0,0049	0,0045	0,0042	0,0027	0,0005	0,0022	0,0001	
11	0,2295	11	-0,0023	-0,0023	-0,0032	-0,0032	0,002	-0,0023	-0,0023	-0,0048	0,0029	0,0029	-0,0013	0,001	0,0008	-0,0014	0,0048	
12	0,3577	12	0,0026	-0,0016	-0,0019	-0,0035	0,0026	0,002	-0,0001	0,0026	-0,003	2,0927	-0,0038	0,002	0,0032	-0,0036	0,0022	
13	0,3012	13	1,2796	0,0002	0,0009	-0,0025	-1,1612	-0,0013	0,0009	0,0002	-0,0028	-0,0013	0,0000	0,0009	-0,0048	-0,0028	-0,0007	
14	0,2867	14	0,0024	-0,0025	0,0007	-0,0044	-0,0009	-2,1562	0,0024	0,0024	0,0024	-0,0016	0,0002	-0,0024	-0,0025	0,0024	-0,0002	
15	0,2252	15	-0,0033	0,0039	0,0025	-0,001	0,0025	0,0018	-0,0033	0,0031	0,0031	-0,0033	0,0001	0,0032	0,0034	-0,001	-0,001	
16	0,3568	15	0,0009	0,0022	-0,0045	1,2938	0,004	0,0009	-0,0035	0,0009	0,0034	-0,0045	-0,0001	-0,0032	-0,0023	0,0048	1,2938	
17	0,2994	16	-0,0018	0,0007	0,0041	-0,0049	0,0034	-0,9965	-0,0013	-0,0003	0,002	-0,0009	0,0042	0,0041	0,0028	0,0048	-0,0006	
18	0,3514	16	-0,0009	-0,0045	0,5908	-1,6067	-0,0032	-0,0009	0,5908	0,0036	-1,6067	-1,6067	0,0011	-0,0029	-1,3509	0,4682	-1,3509	
19	0,3542	17	-1,7982	-1,8177	-0,0002	0,6098	-0,0028	0,6098	0,6098	-0,0007	0,002	-2,1099	-0,0008	-0,0002	-0,0048	-0,001	-0,001	
20	0,2252	18	0,0000	-3,5069	-0,0042	0,0048	-0,0021	0,0005	-3,5069	-3,5069	0,0000	-0,0046	-3,5069	-3,5069	-0,0042	0,004	-0,0042	
21	0,2446	19	0,0031	-0,0049	-0,0021	0,0046	0,0037	-0,0024	2,2421	0,0031	0,8564	-0,0029	-0,0006	0,0027	-0,0006	0,0047	0,0001	
22	0,2443	20	0,0012	-0,0022	-0,0022	-0,0012	0,0035	0,002	0,0035	-0,0012	-1,3756	0,002	-0,0012	0,0012	-0,0044	-0,0012	0,0046	
23	0,3281	20	0,0003	-0,0014	-0,0014	0,0000	0,0043	-0,0027	-0,0009	0,0024	0,0000	0,0000	-0,0021	0,0009	0,0038	0,0024	0,0038	
24	0,2918	24	-0,3753	-0,0026	0,0014	-0,0038	0,0008	0,0004	-0,0024	0,0002	-0,0035	0,0027	0,003	-0,0019	-0,0002	0,001	0,0033	
25	0,2252	25	-0,0012	0,001	0,0039	0,0023	-0,0015	-0,2902	-0,0039	-0,0031	-0,6997	-0,0025	-0,0039	-0,003	-0,003	-0,0039	0,0005	
26	0,3662	25	-0,0024	0,0020	0,0034	0,001	-0,0033	0,0001	0,0004	0,0047	-0,0007	-0,0024	0,0000	0,0019	-0,0031	0,0034	0,0013	
27	0,4117	25	0,0001	0,0022	0,0046	0,0037	0,0046	-0,0039	-0,0008	0,0042	0,0000	-0,0039	0,0008	0,0001	-0,0045	-0,3564	0,0000	
28	0,3237	26	-1,2281	-0,0034	0,5494	-1,1353	0,0013	0,003	0,0023	0,0015	0,2419	0,0028	-0,0028	-0,0041	0,0039	-0,0043	-0,0017	
29	0,2454	28	-0,0035	0,7473	-0,0002	0,0039	-0,0025	1,1347	-0,0025	0,0032	-0,004	-0,0025	-0,0002	0,0018	-0,0025	-0,0025	0,7473	
30	0,2709	29	-0,0015	-0,0012	-0,0048	-0,0011	0,0042	0,0001	-0,0048	1,1998	-0,0048	-0,0013	-0,0048	-0,0048	1,1998	0,003	0,0042	

Tablo D.1: (devamı)

Devir Sayısı	Ağırlık																			
1																				
2																				
3																				
4	0,3888	-0,0037	0,0004																	
5	0,6101	0,0019	-0,0008	0,9207																
6	-0,0001	-0,0005	-0,0042	-0,0004	-1,1736	-0,0049														
7	-0,0038	0,0042	-0,0026	-0,682	0,004	-0,0048	-0,0048	-0,0039	0,003											
8	0,0001	-0,0037	-0,0039	0,0023	-0,0039	-0,0039	-0,0037	-0,0037	-0,0049											
9	0,0041	0,0045	0,003	-0,0018	0,2105	-1,1113	0,2105	0,0028	0,2105	0,2105	-0,0003	0,004								
10	0,0027	-0,0014	-0,0009	0,0004	-0,0023	0,0049	1,1809	0,0044	-0,0003	-0,0014	0,002	0,0544	1,1809	0,0044	0,0031					
11	-0,0045	0,0035	-0,0046	-0,0046	-0,0035	0,0023	-0,0047	-0,0902	-0,0902	-0,001	0,0028	-0,0041	0,003	-0,0019	-0,0902	-0,0902	0,003	-0,004		
12	-0,0024	-0,0013	0,0017	0,0044	0,0049	0,0008	0,0027	0,0023	0,0026	0,0045	0,0033	0,0024	0,0048	0,0043	0,0043	0,0019	-0,0009	0,002		
13	0,0016	0,004	0,0047	-0,0012	-0,001	-0,0001	0,9838	0,0004	0,0004	-0,0038	-0,0045	-0,0001	-0,0026	0,1831	-0,0035	0,0027	-0,3005	0,1831		
14	0,0047	0,0014	-0,0034	-0,0024	0,005	-0,0024	-0,0029	-0,0029	0,0013	-0,0047	0,0015	0,0047	-0,0002	-0,0015	0,7104	-0,0012	0,0018	-0,0049		
15	0,0032	0,0031	-0,0024	1,1354	-0,0024	-0,0025	0,004	0,0013	0,0013	0,0032	0,0001	0,0028	0,0007	1,1354	0,0031	0,0046	0,001	-0,0007		
16	-0,0015	-0,0015	-0,0023	-0,001	-0,001	0,0004	0,0012	0,0012	-0,0019	-0,0028	0,0016	-0,0045	2,1115	0,0016	0,0005	-0,0045	0,0037	-0,0002		
17	0,0042	-0,003	-0,0018	0,0009	-0,0048	0,0008	0,0009	0,0043	0,0019	0,0019	-0,0016	-0,0003	-0,0021	0,0019	0,0023	0,0015	-0,0048	-0,0043		
18	-0,001	-0,0024	-0,0009	0,0014	0,0028	0,0026	0,0025	-0,0005	0,0032	0,0042	-0,0011	0,9371	-0,0042	0,0000	0,0026	0,0018	0,005	0,0025		
19	0,0041	-0,0003	-0,0044	0,0039	0,0025	2,8196	-0,0036	-0,0034	2,8196	-0,0038	-0,005	0,0001	0,0019	-0,0044	-0,003	0,0046	0,0047	0,0021		
20	-0,0012	0,0031	0,0000	-0,0046	0,0007	-0,0014	0,0006	-0,0042	-0,002	0,004	0,004	-0,0046	0,0002	0,4532	0,4532	-0,0014	-0,0049	0,0000		
21	0,0033	0,0001	-0,0031	0,0035	-0,0040	-0,0004	0,0015	0,0009	0,0047	-0,002	0,0027	0,0027	-0,0029	-0,0026	-0,0003	-0,0038	0,0013	0,0016		
22	0,0047	-0,001	0,0026	0,0047	0,0002	-0,0012	-0,0012	-0,0021	-0,003	-0,001	0,0043	0,0028	-0,0021	-0,0027	-0,0048	-0,0016	-0,0022	0,0033		
23	-0,0009	0,0003	-0,004	-0,0006	0,0012	-1,1234	0,0045	0,0045	0,0006	0,0016	-0,0022	0,0048	-0,001	0,0006	0,0006	-0,0022	-0,0036	0,0022		
24	0,003	0,0019	0,0014	-0,0005	0,0014	-0,0014	0,0014	0,003	0,0031	0,0044	0,001	0,0012	0,001	0,0027	0,0032	-0,0035	-0,0035	0,0029		
25	0,001	-0,0026	-0,0046	-0,0004	-0,0012	-0,003	-0,0025	0,0009	-0,0013	-0,6997	0,0033	-0,0033	-0,0009	0,001	0,0003	-0,0042	0,0007	0,0005		
26	-0,0007	-2,4489	0,002	-0,0033	-0,0024	0,0015	-0,0007	-0,0013	-0,0033	0,0012	-0,0014	0,0021	0,0045	0,0044	0,0045	0,0018	-0,0049	-0,0045		
27	-0,0008	-0,0023	0,0000	-0,0026	0,0016	-14,439	-0,0049	-0,0005	-0,0008	0,0022	0,0026	-0,0044	-0,0013	-0,0002	-0,0013	-0,0043	-0,0002	0,0032		
28	0,0036	0,0044	-0,0005	0,0003	0,0036	-0,0043	-0,0031	-0,0016	0,0037	0,0012	0,0003	-0,0031	-0,0016	-0,0004	0,0014	-0,0039	0,0019	0,0032		
29	-0,002	0,0003	0,7473	-0,0010	-0,0002	-0,0025	-0,0025	-0,0025	-0,0001	-0,0025	-0,005	0,0038	-0,0028	0,0042	-0,0042	-0,0009	-0,0017	-0,0048		
30	-0,0011	0,0001	-0,0018	-0,0018	0,0041	0,0029	-0,0003	0,0001	0,0009	1,1998	-0,0012	0,0001	0,0001	-0,0048	-0,0032	-0,0023	0,0044	-0,0042		

Tablo D.1: (devamı)

Devir Sayısı	Ağırlık																			
1																				
2																				
3																				
4																				
5																				
6																				
7																				
8																				
9																				
10																				
11																				
12	0,0044	0,0025	0,0018																	
13	-0,0019	0,0042	0,1831	-0,0033	0,1831	0,0003														
14	1,1387	-0,0038	-0,0028	-0,0028	0,0016	-0,0049	0,0017	0,7104	-0,0015											
15	0,4194	-0,0007	0,0021	0,0046	0,0016	0,0016	0,0046	0,0005	0,4194	-0,0041	0,4194	1,0083								
16	-0,0008	0,0037	0,0011	-0,0045	0,0048	-0,0002	-0,0036	0,0049	0,0045	-0,0008	-0,0037	-0,0008								
17	-0,0003	-0,0015	-0,004	0,0009	-0,0008	0,0016	-0,0021	-0,0043	0,0029	-0,0012	-0,0015	0,0045	0,0036	-0,0049	0,3455					
18	-0,0032	0,0031	-0,0016	-0,0047	-0,1386	0,0031	0,0039	-0,0026	-0,0016	0,0031	0,005	-0,004	-0,0032	0,0022	0,0041					
19	-0,0038	-0,0029	0,0009	-0,0001	0,0046	-0,003	1,1894	0,0046	-0,0036	-0,0017	-0,3104	0,0043	-0,0017	0,0047	0,0033	0,0033	-0,0016	0,0014		
20	0,0027	0,002	0,0007	-0,0008	1,5234	-0,0037	-0,0016	-0,2847	0,0004	1,5234	1,5234	-0,3312	0,0047	0,6577	0,6577	-0,0037	0,0045	0,0043	0,0032	
21	0,0005	-0,0033	0,0046	0,0014	-0,0006	-0,338	0,0019	0,0017	-0,0002	-0,0037	0,0049	-0,0027	-0,338	0,0037	0,0000	-0,0006	0,0047	0,0013	-0,2981	
22	-0,0007	0,0031	-0,0023	0,0029	0,0025	-0,0023	-0,0004	-0,0028	0,005	0,005	-0,0029	0,0032	-0,0024	0,0012	-0,0029	0,0023	0,0029	-0,0029	-0,0028	
23	-0,001	0,0003	0,0048	-1,1234	0,0045	0,0035	0,0024	-0,0024	0,0024	0,0024	0,0015	-0,0014	0,0024	0,0011	0,0049	0,0015	0,0015	-0,0046	0,0025	
24	-0,0015	-0,0049	-0,0043	0,0006	-0,0041	0,0045	-0,0035	-0,0043	0,0018	-0,0023	0,0012	0,0007	0,0012	-0,0035	-0,0006	0,0028	-0,0043	0,0022	0,004	
25	-0,0005	0,003	0,0039	0,0003	0,0024	-0,0032	0,0033	-0,0011	-0,0009	0,0001	-0,0035	-0,0004	0,0003	0,0001	0,2587	-0,001	-0,0005	0,0018	0,0012	
26	0,0007	-0,0045	-0,0012	-0,0012	0,0043	0,0045	-0,0258	0,0001	-0,0014	0,0021	-0,0045	-0,0014	-0,004	0,0043	-0,0046	0,0045	-0,0001	0,0032	0,0002	
27	-0,0018	0,0037	0,0032	-0,0043	-0,0023	0,0042	-0,0018	0,0019	0,0005	-0,0018	-0,0047	0,005	-0,0011	-0,0027	-0,0002	0,0019	-0,0044	-0,0039	-0,0036	
28	0,0003	0,0046	0,0039	-0,0016	-0,0049	0,0033	0,0045	0,0029	-0,0041	0,0041	0,0041	0,0034	0,0001	-0,002	-0,0049	0,002	-0,0009	0,0039	-0,0023	
29	-0,0021	-0,0046	-0,0025	-0,0002	0,0042	-0,0049	-0,0048	-0,0002	-0,0002	0,0014	-0,0032	-0,0017	0,0029	0,0018	-0,0049	-0,0017	-0,0043	-0,0046	-0,0002	
30	-0,0003	-0,0004	-0,2197	-0,0023	0,0044	-0,0003	0,0023	-0,2197	0,0022	-0,001	-0,0003	-0,0032	0,0045	0,0023	0,0023	-0,0027	-0,0048	-0,0032	-0,0005	

Tablo D.1: (devamı)

Devir Sayısı	Ağırlık																			
1																				
2																				
3																				
4																				
5																				
6																				
7																				
8																				
9																				
10																				
11																				
12	0,0044	0,0025	0,0018																	
13	-0,0019	0,0042	0,1831	-0,0033	0,1831	0,0003														
14	1,1387	-0,0038	-0,0028	-0,0028	0,0016	-0,0049	0,0017	0,7104	-0,0015											
15	0,4194	-0,0007	0,0021	0,0046	0,0016	0,0016	0,0046	0,0005	0,4194	-0,0041	0,4194	1,0083								
16	-0,0008	0,0037	0,0011	-0,0045	0,0048	-0,0002	-0,0036	0,0049	0,0045	-0,0008	-0,0037	-0,0008								
17	-0,0003	-0,0015	-0,004	0,0009	-0,0008	0,0016	-0,0021	-0,0043	0,0029	-0,0012	-0,0015	0,0045	0,0036	-0,0049	0,3455					
18	-0,0032	0,0031	-0,0016	-0,0047	-0,1386	0,0031	0,0039	-0,0026	-0,0016	0,0031	0,005	-0,004	-0,0032	0,0022	0,0041					
19	-0,0038	-0,0029	0,0009	-0,0001	0,0046	-0,003	1,1894	0,0046	-0,0036	-0,0017	-0,3104	0,0043	-0,0017	0,0047	0,0033	0,0033	-0,0016	0,0014		
20	0,0027	0,002	0,0007	-0,0008	1,5234	-0,0037	-0,0016	-0,2847	0,0004	1,5234	1,5234	-0,3312	0,0047	0,6577	0,6577	-0,0037	0,0045	0,0043	0,0032	
21	0,0005	-0,0033	0,0046	0,0014	-0,0006	-0,338	0,0019	0,0017	-0,0002	-0,0037	0,0049	-0,0027	-0,338	0,0037	0,0000	-0,0006	0,0047	0,0013	-0,2981	
22	-0,0007	0,0031	-0,0023	0,0029	0,0025	-0,0023	-0,0004	-0,0028	0,005	0,005	-0,0029	0,0032	-0,0024	0,0012	-0,0029	0,0023	0,0029	-0,0029	-0,0028	
23	-0,001	0,0003	0,0048	-1,1234	0,0045	0,0035	0,0024	-0,0024	0,0024	0,0024	0,0015	-0,0014	0,0024	0,0011	0,0049	0,0015	0,0015	-0,0046	0,0025	
24	-0,0015	-0,0049	-0,0043	0,0006	-0,0041	0,0045	-0,0035	-0,0043	0,0018	-0,0023	0,0012	0,0007	0,0012	-0,0035	-0,0006	0,0028	-0,0043	0,0022	0,004	
25	-0,0005	0,003	0,0039	0,0003	0,0024	-0,0032	0,0033	-0,0011	-0,0009	0,0001	-0,0035	-0,0004	0,0003	0,0001	0,2587	-0,001	-0,0005	0,0018	0,0012	
26	0,0007	-0,0045	-0,0012	-0,0012	0,0043	0,0045	-0,0258	0,0001	-0,0014	0,0021	-0,0045	-0,0014	-0,004	0,0043	-0,0046	0,0045	-0,0001	0,0032	0,0002	
27	-0,0018	0,0037	0,0032	-0,0043	-0,0023	0,0042	-0,0018	0,0019	0,0005	-0,0018	-0,0047	0,005	-0,0011	-0,0027	-0,0002	0,0019	-0,0044	-0,0039	-0,0036	
28	0,0003	0,0046	0,0039	-0,0016	-0,0049	0,0033	0,0045	0,0029	-0,0041	0,0041	0,0041	0,0034	0,0001	-0,002	-0,0049	0,002	-0,0009	0,0039	-0,0023	
29	-0,0021	-0,0046	-0,0025	-0,0002	0,0042	-0,0049	-0,0048	-0,0002	-0,0002	0,0014	-0,0032	-0,0017	0,0029	0,0018	-0,0049	-0,0017	-0,0043	-0,0046	-0,0002	
30	-0,0003	-0,0004	-0,2197	-0,0023	0,0044	-0,0003	0,0023	-0,2197	0,0022	-0,001	-0,0003	-0,0032	0,0045	0,0023	0,0023	-0,0027	-0,0048	-0,0032	-0,0005	

Tablo D.1: (devamı)

Devir Sayısı	Ağırlık																		
1																			
2																			
3																			
4																			
5																			
6																			
7																			
8																			
9																			
10																			
11																			
12																			
13																			
14																			
15																			
16																			
17																			
18																			
19																			
20	0,0003	-0,0032																	
21	0,0047	0,0044	0,0015	0,0013	-0,5502														
22	-0,0029	-0,0029	-0,0028	-0,0039	0,0005	0,0043	1,0807	0,0028											
23	-0,0046	0,0049	-0,004	0,0011	-0,0024	-0,0046	0,0014	-0,0039											
24	-0,0017	-0,001	-0,003	-0,0025	-0,0041	0,0028	-0,0039	-0,0044	0,0875	-0,004	0,0045	-0,0025	0,0038	-0,0025	0,0019	0,0022	-0,0039	0,0022	
25	-0,0018	0,003	0,0009	0,0009	-0,0021	0,0044	-0,0039	0,0023	-0,0021	-0,0004	-0,002	-0,0014	0,0003	0,0012	-0,0049	0,005	-0,0026	-0,0037	
26	0,0037	-0,0016	0,0036	0,0018	-0,0032	-0,0044	0,0005	-0,0025	-0,0033	0,003	0,0028	0,0037	-0,9868	-0,0032	-0,0041	0,0002	0,0036	0,0032	
27	-0,003	0,0041	-0,003	-0,0001	0,0029	-0,0035	-0,0048	0,0042	-0,0015	0,0002	0,0049	0,0032	-0,0048	0,4871	-0,0034	-0,0048	0,0002	-0,0048	
28	-0,0028	-0,0044	0,0036	0,002	-0,0003	0,5872	0,0019	-0,0032	-0,0003	-0,0028	0,0005	-0,004	0,0048	0,0001	0,0015	0,0015	0,0048	-0,6	
29	-0,004	0,0015	0,0035	-0,0037	0,0043	0,1916	0,0013	-0,0014	-0,0479	-1,0539	-0,0039	-0,0038	0,004	-0,0479	-0,003	0,0042	-0,0039	-0,0039	
30	-0,0003	-0,0027	0,0027	-0,0024	0,0023	0,0044	0,0007	-0,0016	0,0032	-0,0012	-0,0027	-0,7664	0,0032	-0,93	0,0032	-0,0031	0,0032	0,0032	

Tablo D.1: (devamı)

Devir Sayısı	Ağırlık															Öğrenme oranı		
1																0,9896		
2																0,5938		
3																0,1371		
4																0,5146		
5																0,9207		
6																0,5792		
7																0,1086		
8																0,3318		
9																0,6134		
10																0,2425		
11																0,2478		
12																0,8987		
13																0,3689		
14																0,0222		
15																0,1511		
16																0,7738		
17																0,4664		
18																0,7431		
19																0,822		
20																0,3105		
21																0,7872		
22																0,6973		
23																0,5284		
24	-0,0025	0,0029														0,1141		
25	-0,0004	0,0003	0,0022	0,0016	-0,0039											0,1183		
26	0,0042	0,0005	0,0013	0,0036	-0,0037											0,2974		
27	-0,0046	0,0012	0,0003	0,4871	-0,0036											0,0351		
28	0,0013	-0,0019	0,0003	-0,0032	0,0005	-0,003	-9E-04	-0,0042								0,5021		
29	0,1916	0,0006	0,6241	0,1916	-0,0014	-0,003	-0,004	-0,0037	-0,0039	-0,002	0,1916	0,0017	0,0021	0,0033				0,921
30	-0,93	-0,0017	-0,0027	0,0044	0,0028	0,0031	0,0031	0,0043	-0,0031	-0,766	-0,001	0,0045	0,0043	-0,0017	-0,7664	0,0031	0,0032	0,985

ÖZGEÇMİŞ

Didem Çınar, 30.05.1982 tarihinde Malatya’da doğmuştur. Ankara Fen Lisesi’nden mezun olduğu 2000 yılında İTÜ İşletme Fakültesi Endüstri Mühendisliği bölümünü kazanmıştır. 2005 yılında bu bölümden lisans diplomasını almış ve aynı yıl İTÜ Endüstri Mühendisliği bölümünde yüksek lisans programına girmiştir. İTÜ Endüstri Mühendisliği Bölümünde araştırma görevlisi olarak görev yapmaktadır.