

**YAPAY SİNİR AĞLARI İLE
TÜRKİYE NET ENERJİ TALEP TAHMİNİ**

Hüseyin Avni ES

**YÜKSEK LİSANS TEZİ
ENDÜSTRİ MÜHENDİSLİĞİ ANABİLİM DALI**

**GAZİ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

**OCAK 2013
ANKARA**

Hüseyin Avni ES tarafından hazırlanan “YAPAY SİNİR AĞLARI İLE TÜRKİYE NET ENERJİ TALEP TAHMİNİ” adlı bu tezin Yüksek Lisans tezi olarak uygun olduğunu onaylarım.

Yrd. Doç. Dr. F. Yeşim KALENDER
Tez Danışmanı, Endüstri Mühendisliği Anabilim Dalı

Bu çalışma, jürimiz tarafından oy birliği ile Endüstri Mühendisliği Anabilim Dalında Yüksek Lisans tezi olarak kabul edilmiştir.

Prof. Dr. Serpil EROL
Endüstri Mühendisliği Anabilim Dalı, G.Ü.

Yrd. Doç. Dr. F. Yeşim KALENDER
Endüstri Mühendisliği Anabilim Dalı, G.Ü.

Doç. Dr. Coşkun HAMZAÇEBİ
Endüstri Mühendisliği Anabilim Dalı, K.T.Ü.

Tarih: 14/01/2013

Bu tez ile G.Ü. Fen Bilimleri Enstitüsü Yönetim Kurulu Yüksek Lisans derecesini onamıştır.

Prof. Dr. Şeref SAĞIROĞLU
Fen Bilimleri Enstitü Müdürü

TEZ BİLDİRİMİ

Tez içindeki bütün bilgilerin etik davranış ve akademik kurallar çerçevesinde elde edilerek sunulduğunu, ayrıca tez yazım kurallarına uygun olarak hazırlanan bu çalışmada bana ait olmayan her türlü ifade ve bilginin kaynağına eksiksiz atıf yapıldığını bildiririm.

Hüseyin Avni ES

YAPAY SİNİR AĞLARI İLE TÜRKİYE NET ENERJİ TALEP TAHMİNİ
(Yüksek Lisans Tezi)

Hüseyin Avni ES

GAZİ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
Ocak 2013

ÖZET

Enerji, ülkelerin kalkınma politikaları içinde hayati önem taşıyan stratejik bir alandır. Enerji ihtiyacının, artan nüfus, artan sanayileşme ve gelişen teknolojilere bağlı olarak hızlı bir şekilde artış göstermesi enerji politikalarının önemini daha da artırmaktadır. Enerji politikalarını belirleyebilmek içinse geleceğe yönelik güvenilir ve doğru tahminlere ihtiyaç duyulmaktadır. Bu kapsamda, tez çalışmasında YSA ile sebep-sonuç ilişkisine dayalı enerji talep tahmini gerçekleştirilmiştir. YSA üzerinde araştırmalar yapılarak enerji alanında yaygın olarak kullanılan YSA ve tahmin modelleri incelenmiştir. Türkiye net enerji talebini tahmin etmek için 1970-2010 yılları arasındaki GSYH, nüfus, ithalat, ihracat, bina yüz ölçümü ve taşıt sayısı değişken verileri kullanılarak YSA modeli kurulmuştur. Kurulan YSA modelinin başarısını ve tahmin performansını değerlendirebilmek için regresyon ve zaman seri modelleri geliştirilmiş ve karşılaştırmalar yapılmıştır. Yapılan analizler ve karşılaştırmalar neticesinde YSA daha başarılı tahminler gerçekleştirdiği görülmüş ve 2011-2025 yılları arası Türkiye net enerji talebi tahmin edilmiştir.

Bilim Kodu : 906.3.015
Anahtar Kelimeler : YSA, enerji, çoklu doğrusal regresyon, zaman serileri
Sayfa Adedi : 75
Tez Yöneticisi : Yrd. Doç. Dr. F. Yeşim KALENDER

**FORECASTING NET ENERGY DEMAND OF TURKEY USING
ARTIFICIAL NEURAL NETWORKS**

(M.Sc. Thesis)

Hüseyin Avni ES

**GAZI UNIVERSITY
INSTITUTE OF SCIENCE AND TECHNOLOGY**

January 2013

ABSTRACT

Energy, having vital importance in countries' development policies, is a strategic issue. Rapidly increment of energy demand with population, industry and developing technology increases more importance of energy policies. Reliable and accurate predictions are needed in order to determine energy policy for the future. Within this framework, energy demand forecast based on artificial neural networks (ANN) in this thesis was carried out with the cause-and-effect relationships. By doing research on ANN which are widely used in the field of energy, prediction models were investigated. ANN model has been established with GDP, population, import, export, building surface area and the number of vehicles for Turkey net energy demand forecast between 1970-2010 years. Regression and time series models were developed in order to evaluate success and predict performance of ANN model and comparisons are made. As a result of the analyzes and comparisons, ANN performs seen more successful predictions and Turkey net energy demand forecast between 2011-2025 years were estimated.

Science Code : 906.3.015

Key Words : ANN, energy, multiple linear regression, time series

Page Number : 75

Adviser : Asst. Prof. Dr. F. Yeşim KALENDER

TEŞEKKÜR

Bu çalışma süresince bilgi, deneyim, destek ve önerilerini esirgemeyen Danışman Hocam Sayın Yrd. Doç. Dr. Yeşim KALENDER'e, tez çalışmasının meydana gelmesinde önemli katkısı olduğuna inandığım ve kıymetli tecrübelerinden faydalandığım Sayın Doç. Dr. Coşkun HAMZAÇEBİ'ye, maddi ve manevi desteklerini her zaman yanımda hissettiğim sevgili anneme, babama ve eşime teşekkürlerimi sunmayı bir borç bilirim.

İÇİNDEKİLER

	Sayfa
ÖZET	iv
ABSTRACT	v
İÇİNDEKİLER.....	vii
ÇİZELGELERİN LİSTESİ.....	x
ŞEKİLLERİN LİSTESİ	xi
1. GİRİŞ	1
2. LİTERATÜR ARAŞTIRMASI.....	5
2.1. YSA ile Enerji Talep Tahmini Çalışmaları.....	5
2.2. Türkiye’de Enerji Talep Tahmini Çalışmaları	8
3. YÖNTEM.....	17
3.1. Yapay Sinir Ağlarının Tanımı	17
3.2. Yapay Sinir Ağlarının Tarihçesi.....	18
3.3. Yapay Sinir Ağlarının Özellikleri.....	20
3.3.1. Doğrusal olmama.....	20
3.3.2. Öğrenme.....	21
3.3.3. Genelleme	21
3.3.4. Uyarlanabilirlik.....	21
3.3.5. Hata toleransı.....	21
3.4. Yapay Sinir Ağlarının Avantajları ve Dezavantajları.....	22
3.4.1. Avantajları.....	22

Sayfa

3.4.2. Dezavantajları.....	23
3.5. Yapay Sinir Ağları'nın Uygulama Alanları	23
3.6. Yapay Sinir Ağlarının Yapısı ve Temel Bileşenleri	24
3.6.1. Biyolojik sinir hücresi.....	24
3.6.2. Yapay sinir hücresi	27
3.6.3. Yapay sinir hücresinin çalışma prensibi	33
3.6.4. Yapay sinir ağı yapısı	34
3.6.5. Yapay sinir ağlarının eğitimi ve testi.....	35
3.7. Yapay Sinir Ağlarının Sınıflandırılması	36
3.7.1. Tipine göre YSA'lar	37
3.7.2. Öğrenme yöntemine göre YSA'lar.....	37
3.7.3. Yapısına göre YSA'lar.....	39
3.7.4. Katman sayılarına göre YSA'lar	40
3.8. Çok Katmanlı Algılayıcı	40
3.8.1. ÇKA modellemede önemli noktalar	46
4. YSA ile Türkiye Net Enerji Talep Tahmini.....	54
4.1. Veri	54
4.2. YSA Uygulaması.....	56
4.2.1. Ağ yapısı	56
4.2.2. Veri düzenleme ve dönüştürme	56
4.2.3. Ağ optimizasyonu.....	56
4.2.4. Bulgular.....	57
4.3. Karşılaştırma	60

	Sayfa
4.3.1. Çoklu doğrusal regresyon modeli.....	60
4.3.2. YSA zaman serisi modeli.....	63
4.3.3. Tahmin	65
5. SONUÇ	68
KAYNAKLAR.....	70
ÖZGEÇMİŞ	75

ÇİZELGELERİN LİSTESİ

Çizelge	Sayfa
Çizelge 2.1. YSA ile gerçekleştirilen enerji talep tahmin çalışmaları	8
Çizelge 2.2. Türkiye’de enerji alanında yapılan çalışmalar	16
Çizelge 3.1. YSA ile ilgili yapılan çalışmaların kronolojik sıralaması	19
Çizelge 3.2. Sinir sistemi ile YSA’nın benzerlikleri	26
Çizelge 3.3. İstatistiksel yöntemlerle yapay sinir ağlarının benzeşimleri.....	27
Çizelge 3.4. Toplama fonksiyonu örnekleri	29
Çizelge 4.1. Çalışmada kullanılan bağımsız değişkenler	55
Çizelge 4.2. YSA modeli OMYH değeri	58
Çizelge 4.3. Test kümesi OMYH değeri.....	59
Çizelge 4.4. MİNİTAB analiz sonuçları	61
Çizelge 4.5. ÇDRM ve kYSA tahmin değerleri ve OMYH.....	63
Çizelge 4.6. ZS ve YSA tahmin değerleri ve OMYH	65
Çizelge 4.7. Senaryolar ve yüzdelik değerleri.....	66
Çizelge 4.8. Senaryolara göre YSA tahmin değerleri.....	66

ŞEKİLLERİN LİSTESİ

Şekil	Sayfa
Şekil 3.1. Sinir Hücresi	26
Şekil 3.2. Biyolojik ve yapay sinir ağları.....	27
Şekil 3.3. Yapay sinir hücresi.....	28
Şekil 3.4. Doğrusal aktivasyon fonksiyonu.....	31
Şekil 3.5. Basamak Fonksiyonu	31
Şekil 3.6. Sigmoid fonksiyonu	32
Şekil 3.7. Hiperbolik Tanjant Fonksiyonu	33
Şekil 3.8. Bir yapay sinir ağının çalışması örneği.	33
Şekil 3.9. Çok katmanlı bir yapay sinir ağı	35
Şekil 3.10. YSA'ların sınıflandırılması.....	36
Şekil 3.11. Geri Beslemeli Ağ Yapısı.....	37
Şekil 3.12. Öğretmenli öğrenme.....	39
Şekil 3.13. İleri beslemeli geri yayılım yapay sinir ağı yapısı	41
Şekil 4.1. Türkiye net enerji talebi için YSA yapısı	56
Şekil 4.2. Eğitim kümesi HKT grafiği	57
Şekil 4.3. Gerçek değerler ve tahmin değerleri	59
Şekil 4.4. Durbin-Watson testi kararlarının şematik gösterimi	62
Şekil 4.5. Çoklu doğrusal regresyon modelinin hata payları grafiği	62
Şekil 4.6. Zaman serisi tahmini için kurulan ÇKA.....	64
Şekil 4.7. Senaryolara göre YSA tahmin grafiği.....	67

SİMGELER VE KISALTMALAR

Bu çalışmada kullanılmış bazı simgeler ve kısaltmalar, açıklamaları ile birlikte aşağıda sunulmuştur.

Kısaltmalar	Açıklama
ACO	Karınca Koloni Optimizasyonu
ADALINE	Adaptif Doğrusal Eleman
ANFIS	Adaptif Ağ Tabanlı Bulanık Çıkarım Sistemi
ARIMA	Otoregresif Bileşik Hareketli Ortalama
ARMA	Otoregresif Hareketli Ortalama
ÇKA	Çok Katmanlı Algılayıcı
DEKTMK	Dünya Enerji Konseyi Türk Milli Komitesi
ETKB	Enerji ve Tabii Kaynaklar Bakanlığı
GA	Genetik Algoritma
GSMH	Gayri Safi Milli Hasıla
GSYH	Gayri Safi Yurtiçi Hasıla
HKT	Hata Kareleri Toplamı
LR	Lineer Regresyon
NLR	Lineer Olmayan Regresyon
OMYH	Ortalama Mutlak Yüzde Hata
PSO	Parçacık Sürü Optimizasyonu
SARIMA	Mevsimsel Otoregresif Bileşik Hareketli Ortalama
YSA	Yapay Sinir Ağları
YSH	Yapay Sinir Hücresi

1. GİRİŞ

Bilimsel olarak enerjinin tanımı özetle “ iş yapma kapasitesi veya kabiliyeti ” olarak tanımlanmaktadır. En genel anlamıyla iş yapabilme gücüne sahip evrensel bir kavram olan enerji, üretim işlemlerinde kullanılması zorunlu bir girdidir. Ayrıca toplumların refah düzeylerinin yükseltilmesi için gerekli bir hizmet aracı olarak ekonomik ve sosyal kalkınmanın temel taşlarından birisini teşkil etmektedir [Şahin, 1994].

Enerji kaynaklarının sınıflandırılması; geleneksel tasnif, kaynak kullanım yeri ve amacına göre sınıflandırılabilceğı gibi ticari ve gayri ticari olarak da sınıflandırılabilir. Enerji kaynaklarının dönüştürülebilirliğine göre yani enerji kaynaklarının bir dizi işlemde geçirilip geçirilmediğine göre yapılan tasnif geleneksel tasnif olarak nitelenip, kaynaklar birincil ve ikincil enerji kaynakları olarak adlandırılmaktadır. Birincil enerji kaynakları doğada bulundukları şekliyle ve herhangi bir işleme gerek kalmadan kullanılabilen kaynaklardır. İkincil enerji kaynakları ise birincil enerji kaynaklarının belirli bir işlemler silsilesinden geçirilerek meydana gelen kaynaklardır [Hepbaşlı ve Özgener, 2004].

Enerji sektörü, ülkelerin kalkınma politikaları içinde hayati önem taşıyan stratejik bir alan niteliğindedir. Tüketim miktarı sürekli artan enerji, üretildiğı kaynakların sahip olduğı bazı özellikler nedeniyle önemini her geçen gün daha da artırmaktadır. Fosil yakıtlar olan petrol, doğal gaz ve kömürün gelecekte tükenebilecek yakıtlar olması, dünya üzerinde homojen bir dağılıma sahip olmaması, yenilenebilir enerji kaynaklarının her ülkede kullanabilecek özellik ve kapasitede olmaması, ülkeler için enerji kaynaklarını çok daha stratejik bir konuma getirmektedir [İnternet].

Enerji kaynaklarına sahip olmayan ve enerji ihtiyaçlarını ithal etmek zorunda kalan ülkeler, kendileri bakımından stratejik olmaktan çıkıp, 'kritik' bir önem kazanmış olan enerji kaynaklarının arz güvenliğinin, ulusal güvenlik ile aynı manada görülmesi nedeniyle enerji hammaddelerinin arz güvenliğini sağlamak için farklı yollar

izlemektedirler. Bu ülkeler, elde edemedikleri bu enerji kaynaklarının taşınmasını sağlayan hatların kendi ülkelerinden geçmesini istemektedirler. Son yıllarda dünya üzerinde bu hatlara sahip olmak için büyük bir mücadele yaşanmaktadır ve yaşanmaya devam edecektir [Çakır, 2008].

Sanayileşmiş ve kalkınmış dünya ülkesine haline gelmek bütün devletlerin isteğidir. Kalkınmayı sağlayan en temel sektör sanayi sektörüdür. Sanayi sektörünün en temel girdisinin enerji olması, dünya genelinde enerji tüketiminde artışın yaşanmasına neden olmaktadır. Enerji tüketiminin sürekli artması ve enerji kaynaklarının özellikleri, enerji konusunu son yıllarda dünya gündeminin en üst sırasına taşımıştır. Dünya gündeminin en üst sırasında olan bir konunun elbette Türkiye gündeminde de en üst sıralarda olması şarttır.

Enerji ihtiyacının, artan nüfus, artan sanayileşme ve gelişen teknolojilere bağlı olarak hızlı bir şekilde artması ve bu ihtiyacın üretiminde sıkıntıların yaşanması, enerji kaynaklarının fiyatlarında çok kısa periyotlar içinde çok büyük değişiklikler yaşanması ve enerji arz sistemlerinde değişikliklerin yaşanması, dünya üzerindeki dengeleri altüst ederek büyük sorunlara neden olmaktadır. Bütün bu olumsuzluklara rağmen, enerjinin hayatımızın olmazsa olmazlarından birisi olması, enerji ve enerji kaynaklarının çok iyi değerlendirilmesini ve çok iyi enerji politikalarının uygulanmasını zorunlu hale getirmektedir.

Enerji politikalarını belirleyebilmek için bölgenin enerji kaynakları hakkında bilgi sahibi olmak, geleceğe yönelik tahminlerde bulunmak oldukça önemlidir. Geleceğe yatırım yapabilmek için yakın geleceği kestirebilmek gerekir. Bu nedenle hayatımızın olmazsa olmazlarından olan enerji talebini karşılayabilmek için başarılı tahminler yapmak oldukça önem arz etmektedir.

Herhangi bir değişkenin gelecekte alacağı değerlerin tahmini, değişkenin geçmiş dönemlerdeki gözlem değerleri kullanılarak oluşturulan modeller yardımı ile sağlanır. Doğru model, gerçeğe daha yakın tahminler üretilmesini sağlayacaktır.

Tahmin yöntemleri; nitel ve nicel tahmin yöntemleri olarak iki ana gruba ayrılırlar. Her iki tahmin yönteminin dayanağı ilgili değişkene ait gözlem değerleridir.

Nitel tahmin yöntemi, çalışılan konu üzerinde uzman olan bireyin görüş ve deneyimlerine dayanmaktadır. Aynı veriler için farklı kişiler farklı tahminlerde bulunabilir. Ancak uygulamasının kolay olması, fazla çaba ve zaman gerektirmemesi olumlu yanı olarak sayılabilir. Ayrıca genellikle ucuz olmaları ve ileri derecede istatistiksel yeteneklere ihtiyaç duymaması da tercih edilmesinde önemli bir etkidir. [Çuhadar, 2006].

Nicel tahmin yöntemleri ise matematiksel modellere dayanan yöntemlerdir. Nicel tahmin yöntemleri, yeterli miktarda sayısal bilginin mevcut olduğu durumlarda kullanılabilir. Nicel tahmin yöntemleri ile tahminde bulunulacağı zaman şu üç şartın sağlanmış olması gereklidir: Geçmişe ait bilginin mevcudiyeti, bu bilginin sayısal bir biçimde ifade edilebiliyor olması ve değişkenin geçmişte gösterdiği yapının gelecekte de devam edeceği düşüncesinin geçerli olması. Geçmiş gözlem değerleri kullanılarak sürecin oluşmasına katkıda bulunan ilişkiler belirlenir ve bu ilişkilerin geleceği nasıl şekillendireceği tespit edilmeye çalışılır. Nicel tahminde bulunabilmek için iki temel yaklaşım kullanılmaktadır: sebep-sonuç ilişkisine ve zaman serileri analizine dayalı modeller. [Hamzaçebi, 2011].

Bu çalışmada nicel tahmin metotlarından olan yapay sinir ağları (YSA) ile enerji alanında sebep-sonuç ilişkisine dayalı tahmin çalışması gerçekleştirilecektir.

YSA, tahmin çalışmalarında oldukça başarılı sonuçlar vermekte ve doğrusal olmayan problemleri modelleyebilmesiyle diğer tahmin yöntemlerinin önüne geçmektedir. Bu nedenle enerji alanında da YSA ile tahmin çalışmaları yapılmış ve yapılmaktadır. Bu eksende ikinci bölümde literatür araştırması kısmı yer almaktadır. Literatür araştırması kısmında öncelikle sebep-sonuç ilişkisine dayalı YSA ile gerçekleştirilen çalışmalar dikkate alınacaktır. Daha sonra Türkiye üzerinde enerji ile ilgili ortaya konulan çalışmalara vakıf olmak için zaman serisi ve sebep-sonuç ilişkisine dayanan tahmin yöntemleri çalışmaları incelenecektir.

Üçüncü bölümde çalışma kapsamında kullanılacak olan YSA ayrıntılı bir şekilde anlatılacak olup, dördüncü bölümde uygulama kısmı gerçekleştirilerek bulgular elde edilecektir. Elde edilen sonuçların performansını değerlendirmek için çoklu doğrusal regresyon modeli ve zaman seri modeli geliştirilecektir. Bu modeller ile YSA modeli karşılaştırılacak olup 3 farklı senaryoya göre tahmin çalışmaları hesaplanacaktır. Beşinci bölümde sonuçlar ortaya konulacak ve değerlendirmeler yapılacaktır.

2. LİTERATÜR ARAŞTIRMASI

Enerji, ülkelerin kalkınma politikaları içinde hayati önem taşıyan stratejik bir araçtır. Sürdürülebilir kalkınmayı desteklemek için enerji politikalarının belirlenmesinde doğru ve güvenilir tahmin çalışmalarının yeri büyüktür. Bu nedenle enerjiyle ilgili olarak literatürde birçok talep tahmini çalışmaları yapılmış ve yeni tahmin modelleri türetilmiştir. Örneğin; Himanshu ve Lester (2008) zaman serilerini kullanarak Sri Lanka'nın, Bessec ve Fouquau (2008) çok değişkenli regresyon analizine dayalı deneysel bir model geliştirerek Ürdün'ün elektrik talebini tahmin etmişlerdir. Wang ve ark. (2010) adaptif parçacık sürü optimizasyonu ile mevsimsel otoregresif bileşik hareketli ortalama (SARIMA) tahmin modeli, mevsimsel üstel düzeltme modeli ve ağırlıklı destek vektör makinelerini kullanarak yeni bir model geliştirmişler ve elektrik yük tahmini için bu modeli kullanmışlardır. Lee ve Tong (2011) genetik algoritmayla desteklenen gri modeli kullanarak Çin'in enerji talebini tahmin etmişlerdir. Suganthi ve Samuel (2012) enerji alanıyla ilgili olarak yapılan bu tür çalışmaları derleme yoluna gitmiş ve talep tahmin modellerini, kullanılan ve geliştirilen tekniklere göre sınıflandırmışlardır. Daha geniş enerji talep tahmin modellerine ulaşmak için Suganthi ve Samuel'in (2012) çalışmaları incelenebilir.

Çalışmanın bu aşamasında öncelikle, tahmin tekniği olarak kullanılacak olan YSA ile yapılan çalışmalar incelemek ve literatürde YSA modelinde kullanılan değişkenler ve tahmin modelindeki önemli noktalar tespit edilecek, daha sonra Türkiye'de ortaya konulan enerji talep tahmini çalışmaları gözden geçirilecektir. Böylece YSA konusuna ve Türkiye'deki enerji çalışmalarına hâkim olunarak alt yapısı sağlam bir çalışma ortaya konulabilecektir.

2.1. YSA ile Enerji Talep Tahmini Çalışmaları

YSA, tahmin çalışmalarında oldukça başarılı sonuçlar vermekte ve doğrusal olmayan problemleri modelleyebilmesiyle diğer tahmin yöntemlerinin önüne geçmektedir. Bu nedenle birçok alanda olduğu gibi enerji alanında da YSA ile tahmin çalışmaları yapılmış ve yapılmaktadır.

Sözen ve ark. (2005) çalışmalarında Türkiye'nin net enerji tüketiminin tahmini için yapay sinir ağlarını kullanmışlardır. Sinir ağlarını eğitmek için 2 model geliştirmişlerdir. 1975-2003 yılları arasındaki nüfus, brüt üretim, kurulu kapasite, ithalat ve ihracat verileri öğrenme için kullanılmıştır. Elde edilen sonuçlar gerçek verilerle karşılaştırılarak yapılacak tahminin gerçekçi olacağı sonucuna varılmıştır.

Pao (2006) çalışmasında Tayvan'da elektrik tüketiminde ekonomik faktörlerin (milli gelir, nüfus, gayri safi yurtiçi hasıla (GSYH), tüketici fiyatları endeksi) etkisini incelemek ve tahmin modeli geliştirebilmek için YSA ile birlikte lineer ve lineer olmayan istatistiksel modelleri kullanmıştır. Ocak 1990 ile Aralık 2002 tarihleri arasındaki 156 aylık veriler kullanılarak modeller kurulmuştur. Sonuçlar karşılaştırıldığında YSA, elektrik tüketimi tahmin modelleri için lineer modellerden daha iyi sonuç vermiştir. Ayrıca bu çalışma Tayvan'da elektrik tüketimindeki önemli ekonomik faktörlerin saptanabilmesini sağlayarak araştırmacılara yol göstermektedir.

Sözen ve Arcaklıoğlu (2007) Türkiye'nin net enerji tüketimini tahmin etmek için yapay sinir ağlarını kullanmışlardır. Ekonomik göstergeler ve nüfus faktörlerini dikkate alarak 3 farklı model kurmuşlardır. 37 yıllık (1968-2005) verileri kullanarak öğrenmeyi gerçekleştirmiştir. Farklı modelleri karşılaştırarak gelecek için güvenilir sonuçlar elde etmeyi başarmışlardır.

Kavaklıoğlu ve ark. (2009) Türkiye elektrik tüketimini tahmin etmek için; yapay sinir ağlarıyla 1975-2006 yılları arasındaki verileri kullanarak 2027 yılına kadar elektrik tüketimini tahmin etmişlerdir. Ekonomik göstergelerden olan gayri safi milli hasıla (GSMH), nüfus, ithalat ve ihracat fonksiyonlarını kullanarak elektrik tüketimini modellemişlerdir. İthalat-ihracat oranları ve sadece zaman girişleriyle de modellemeler yapmışlardır. Daha sonra mutlak ve yüzde hata karelerine dayanan modeller arasında performans karşılaştırması yaparak sonuçları değerlendirmişlerdir.

Geem ve Roper (2009) Güney Kore'nin enerji talebini tahmin etmek için ileri beslemeli çok katmanlı YSA modelini kullanmışlardır. 1980-2007 yılları arasındaki GSYH, nüfus, ithalat ve ihracat verilerini kullanarak 2008-2025 yılları için toplam

enerji tüketimini hesaplamışlardır. Elde edilen sonuçlar doğrusal regresyon ve üstel model ile elde edilen sonuçlarla karşılaştırılmıştır. YSA'nın diğer yöntemlere göre daha iyi tahminler yaptığı saptanmıştır.

Ekonomou (2010) Yunanistan'ın toplam enerji talebini tahmin etmek için YSA'nın çok katmanlı algılayıcı modelini kullanmıştır. 1992-2008 yılları arasındaki ortam sıcaklığı, kurulu güç kapasitesi, GSYH ve yerleşim yeri elektrik tüketimi verilerini kullanarak 2010, 2012 ve 2015 yılları için toplam enerji tüketimini tahmin etmiştir. Elde edilen sonuçlar destek vektör ve regresyon modelleri ile karşılaştırılarak önerilen modelin kabul edilebilir düzeyde olduğu saptanmıştır.

Limanond ve ark. (2011) çalışmalarında gelecek 20 yıl için Tayland'ın ulaştırma enerji talebini tahmin etmişlerdir. Bunun için log-lineer regresyon ve YSA'nı kullanmıştır. 1989-2008 yılları arasındaki GSYH, nüfus ve kayıtlı araç sayıları değişkenlerini kullanarak 2010, 2015, 2020, 2025, 2030 yıllarındaki ulaştırma enerji tüketimi hesaplamışlardır.

Kankal ve ark. (2011) Türkiye'nin enerji tüketimini sosyo-ekonomik ve demografik değişkenler kullanarak tahmin etmişlerdir. Gayri safi yurtiçi hasıla, nüfus, ithalat-ihracat miktarları ve istihdam değişkenleriyle regresyon analizi ve yapay sinir ağlarını kullanarak 2008-2014 yılları Türkiye enerji tüketimi tahmin edilmiştir. Elde edilen tahmin sonuçları birbirleriyle ve resmi tahminlerle karşılaştırılarak sonuçlar ortaya konmuştur.

Geem (2011) çalışmasında ulaştırma enerji talebini tahmin etmek için GSYH, nüfus, petrol fiyatları, kayıtlı araç sayısı ve yolcu taşıma miktarı gibi çeşitli değişkenleri kullanarak YSA ve regresyon modelleri kurmuşlardır. Değişkenler için 1990-2007 yılları arasındaki veriler kullanarak 2008-2025 yıllarındaki ulaştırma enerji talebini hesaplamışlardır.

Bilgili ve ark. (2012) Türkiye'deki konut ve sanayi sektörlerinin enerji tüketimini tahmin etmek için YSA, lineer regresyon (LR) ve lineer olmayan regresyon (NLR)

modellerini kullanmıştır. Kurulu kapasite, brüt elektrik üretimi, nüfus ve toplam abone sayısı değişkenleriyle yapılan hesaplamalar literatürde yapılan çalışmalar ve Enerji ve Tabii Kaynaklar Bakanlığı(ETKB)’ndaki sonuçlarla karşılaştırılmıştır. Bu karşılaştırmalar neticesinde YSA yönteminin; LR ve NLR modellerinden daha iyi sonuç verdiği mukayese edilmiştir.

Bu bölümde literatürde bulunan, YSA ile bazı enerji talep tahmini çalışmaları verilmiş olup; bu makaleler Çizelge 2.1’de özet halinde sunulmuştur.

Çizelge 2.1. YSA ile gerçekleştirilen enerji talep tahmin çalışmaları

Yazarlar	Değişkenler	Veri Yılı	Enerji Türü	Tahmin Dönemi
Sözen ve ark. (2005)	Nüfus, brüt üretim, kurulu kapasite, ithalat, ihracat	1975-2003	Enerji talebi	Model kuruldu
Pao (2006)	Milli gelir, GSYH, tüketici fiyat endeksi	Ocak 1990-Aralık 2002	Elektrik enerji talebi	Model kuruldu
Sözen ve Arcaklıoğlu (2007)	Nüfus, ekonomik göstergeler	1968-2005	Enerji talebi	Model kuruldu
Kavaklıoğlu ve ark. (2009)	GSMH, nüfus, ithalat ve ihracat	1975-2006	Elektrik enerji talebi	2007-2027
Gem ve Roper (2009)	GSYH, nüfus, ithalat, ihracat	1980-2007	Toplam enerji talebi	2008-2025
Ekonomou (2010)	Sıcaklık, kurulu güç kapasitesi, GSYH, yerleşik elektrik tüketimi	1992-2008	Toplam enerji talebi	2010, 2012, 2015
Limanond ve ark. (2011)	GSYH, nüfus ve kayıtlı araç sayıları	1989-2008	Ulaştırma enerji talebi	2010, 2015, 2020, 2025, 2030
Kankal ve ark. (2011)	GSYH, nüfus, ithalat, ihracat, iş	1980-2007	Enerji talebi	2008-2014
Geem (2011)	Petrol fiyatları, kayıtlı araç sayısı, yolcu taşıma miktarı	1990-2008	Ulaştırma enerji talebi	2008-2025
Bilgili ve ark. (2012)	Kurulu kapasite, brüt elektrik üretimi, nüfus ve toplam abone sayısı	1990-2007	Elektrik enerji talebi	2008-2015

2.2. Türkiye’de Enerji Talep Tahmini Çalışmaları

Gelişen ve gelişmekte olan ülkeler için stratejik öneme sahip olan enerji konusu şüphesiz Türkiye içinde çok önemli bir argümandır. Bu nedenle dünyada olduğu gibi Türkiye’de de enerji talep tahminine yönelik çalışmalar yapılagelmektedir. Bu kısımda Türkiye’de gerçekleştirilen enerji talep tahmini çalışmaları hakkında bilgi sahibi olmak amacıyla literatür incelenmiş, yapılan çalışmalar özetlenmiş ve tablo halinde sunulmuştur.

Ceylan ve Öztürk (2004) Türkiye’deki ekonomik göstergelere göre enerji talep tahmin için genetik algoritma yaklaşımlarını kullanarak bir genetik algoritma enerji talep modeli geliştirmişlerdir. 1970-2001 yılları arasındaki ekonomik göstergelerden GSMH, nüfus, ithalat ve ihracat verileri kullanılarak farklı senaryolara göre 2002-2025 yılları arasındaki toplam enerji talebi tahmin edilmiştir. Geliştirilen modelin tahmin hatası ETKB projeksiyonu ile karşılaştırıldığında daha düşük düzeyde olduğu gösterilmiştir.

Hamzaçebi ve Kutay (2004) uzun dönemli elektrik enerjisi tüketimi tahmininde yapay sinir ağlarının kullanmıştır. 1970-2002 yılları arasındaki elektrik enerji tüketimi değerleri ve nüfus bilgileri ile model geliştirilerek 2003-2010 yılları arasındaki tahminler ortaya konulmuştur. Yapay sinir ağları teknikleri ile bulunan sonuçlar, Box-Jenkins modelleri ve regresyon tekniği ile karşılaştırılmıştır. Bulunan sonuçlar yapay sinir ağlarının elektrik enerjisi tüketiminde iyi bir tahmin aracı olduğunu göstermiştir.

Sözen ve ark. (2004) makalede iki durumdan bahsetmektedir. Öncelikle ana tema; YSA kullanarak Türkiye’deki güneş enerji potansiyelini ortaya koymak ve sonrasında da geliştirilen sinir ağları yazılımlarıyla farklı öğrenme algoritmalarını ve lojistik sigmoid transfer fonksiyonlarını kullanarak en iyi yaklaşımı belirlemek olmuştur. Meteorolojik ve coğrafik veriler kullanılarak eğitilen ve test edilen model ağ izleme istasyonları bulunmayan bölgelerde güneş kaynağı potansiyelini değerlendirmede daha fazla hassasiyete gösteren YSA modeli sonucunda güneş enerjisi potansiyeli aylık haritalar şeklinde oluşturulmuştur.

Öztürk ve ark. (2004) Türkiye’de kullanılabilir petrol tahmini için genetik algoritma yaklaşımını kullanmışlardır. 1990-2000 yılları arasındaki GSMH ve araç sahiplerinin yüzdelik verilerini kullanarak 2001-2020 yılları arasındaki kullanılabilir petrol talebini tahmin etmişlerdir. Tahmin için geliştirilen üç farklı modelden ortalama tahmin hatası en az olan tercih edilmiş ve tahmin tekniğinin kullanılabilir olduğu gösterilmiştir.

Sözen ve ark. (2005) çalışmalarında Türkiye'nin net enerji tüketiminin tahmini için yapay sinir ağlarını kullanmışlardır. Sinir ağlarını eğitmek için 2 model geliştirmişlerdir. 1975-2003 yılları arasındaki nüfus, brüt üretim, kurulu kapasite, ithalat ve ihracat verileri öğrenme için kullanılmıştır. Elde edilen sonuçlar gerçek verilerle karşılaştırılarak yapılacak tahminin gerçekçi olacağı sonucuna varılmıştır.

Haldenbilen ve Ceylan (2005) çalışmalarında genetik algoritmayı kullanarak etkin bir ulaştırma talep tahmini elde edebilmek için üç formda enerji talep denklemi geliştirmişlerdir. 1970-2000 yılları arasındaki nüfus, GSYH ve araç-km verilerini kullanarak lineer, üstel ve ikinci dereceden üç farklı model geliştirilmiştir. İkinci derece formundaki modelden en iyi sonuçlar elde edilmiş ve 2020 yılına kadarki talep tahmini gerçekleştirilmiştir.

Ediger ve ark. (2006) Türkiye'nin yerli fosil yakıt üretimini için en olası eğriyi tahmin etmeyi amaçlamışlardır. Çalışmalarında 1950'den 2003 yılına kadarki tarihsel verileri karşılaştırmalı bir şekilde regresyon, otoregresif bileşik hareketli ortalama (ARIMA) ve mevsimsel otoregresif bileşik hareketli ortalama (SARIMA) modellerine uygulayarak fosil yakıt üretimi tahmini için karar destek sistemleri geliştirmişlerdir. Farklı fosil yakıt tipleri için farklı tahmin modelleri önerilmiş ve tahminler yapılmıştır.

Murat ve Ceylan (2006) çalışmalarında sosyo-ekonomik ve ulaştırmayla ilgili göstergeleri kullanarak 2020 yılına kadarki ulaştırma talep tahmini için YSA'nı kullanmışlardır. 1970-2001 yılları arasındaki nüfus, GSYH ve toplam yıllık ortalama araç-km verileri kullanılarak model geliştirilmiştir. Test aşamasında enerji verileriyle model tahminleri karşılaştırılarak model doğruluma gerçekleştirilmiş ve projeksiyonlar iki farklı senaryoya göre yapılmıştır. Elde edilen sonuçların ulaştırma enerji tahmin problemi için uygun yöntem olduğu belirtilmiştir.

Akay ve Atak (2007) çalışmalarında gri tahmin modelini kullanarak Türkiye'nin toplam ve sektörel elektrik enerji talebini tahmin etmişlerdir. 1970-2004 yılları arasındaki toplam ve sektörel elektrik enerji verilerini kullanarak 2006-2015 yılları

için tahmin değerlerini hesaplamışlardır. Elde edilen sonuçlar, ETKB'nın enerji talep modelinin sonuçlarıyla karşılaştırılmış ve gri tahmin modelinin daha doğru sonuçlar verdiği saptanmıştır.

Ediger ve Akar (2007), çalışmalarında Türkiye'nin gelecekteki birincil enerji talebinin 2005 yılından 2020 yılına kadar olan tahminini hesaplamak için ARIMA ve SARIMA yöntemlerini kullanmışlardır. Bu yöntemin bireysel tahminlerden daha güvenilir olduğunu ve bireysel enerji ve toplam birincil enerji kaynaklarının ortalama yıllık büyüme oranlarının azalacağı sonucuna varmışlardır.

Sözen ve Arcaklıoğlu (2007) Türkiye'nin net enerji tüketimini tahmin etmek için yapay sinir ağlarını kullanmışlardır. Ekonomik göstergeler ve nüfus faktörlerini dikkate alarak 3 farklı model kurmuşlardır. 37 yıllık (1968-2005) verileri kullanarak öğrenmeyi gerçekleştirmiştir. Farklı modelleri karşılaştırarak gelecek için güvenilir sonuçlar elde etmeyi başarmışlardır.

Erkan (2007) çalışmasında elektrik talep tahmini için ARIMA modelini kullanmıştır. Çalışma sonucunda tüketicilerin fiyat ve gelir değişikliklerine yanıtlarının oldukça kısıtlı olduğunu; bu nedenle Türk elektrik piyasasının ekonomik düzenleme yapmasının gerekli olduğu sonucuna varılıyor. Diğer çıkarılan sonuç ise sağlıklı elektrik piyasası ve tutarlı enerji politikalarının gelişimini tehlikeye sokabilen elektrik taleplerinin oldukça yüksek tutulduğu güncel resmi elektrik talep gösterimlerinden anlaşılmaktadır.

Hamzaçebi (2007) Türkiye'nin 2020 yılına kadar sektörel bazdaki elektrik enerji tüketimini tahmin etmiştir. Bu tahminde veri yapısındaki doğrusal olmayan ilişkileri modelleyen ve aynı zamanda birden fazla değişkenin gelecek değerlerini tahmin eden YSA'nı kullanmıştır. Bulunan tahmin sonuçları resmi tahminlerle karşılaştırılmıştır.

Toksarı (2007) Türkiye enerji talep tahmini için karınca kolonisi optimizasyon (ACO) modelini kullanmıştır. ACO enerji talep tahmini için 1979-2005 yılları

arasındaki nüfus, GSYH, ithalat ve ihracat verilerini kullanmıştır. 3 farklı senaryo için 2025 yılına kadarki tahminler yapılmış ve sonuçlar ETKB'nin tahminleriyle karşılaştırılmış ve değerlendirmeler yapılmıştır.

Canyurt ve Öztürk (2008) çalışmalarında senaryolar üreterek Türkiye'nin fosil yakıt tüketimini analiz etmek ve gelecek dönemlerin tahmini için genetik algoritmayı kullanmışlardır. Lineer olmayan formlarda geliştirilen modeller Türkiye'nin petrol, kömür ve doğal gaz talebi için uygulanmıştır. Genetik algoritma talep tahmin modelleri; GSYH, nüfus, ithalat ve ihracat verilerine dayanan fosil yakıtların (petrol, kömür, doğal gaz) talep değerlerini tahmin etmek için geliştirilmiştir. 2020 yılına kadar elde edilen tahminler Dünya Enerji Konseyi Türk Milli Komitesi (DEKTMK) sonuçlarıyla karşılaştırılmış ve analizler yapılmıştır.

Ünler (2008) Türkiye'nin toplam enerji talep tahmini etkin bir şekilde gerçekleştirebilmek için parçacık sürü algoritmasının enerji talep tahmin modelini kullanmıştır. Bu çalışma için 1979-2005 yılları arasındaki GSMH, nüfus, ithalat, ihracat ve büyüme oran verilerini kullanmış ve 2006-2025 yıllarını için tahmin sonuçlarına ulaşmıştır. Algoritmanın doğruluğunu belirleyebilmek için aynı problem için geliştirilen karınca kolonisi optimizasyonu ile elde edilen tahmin sonuçlarını karşılaştırmıştır.

Kavaklıoğlu ve ark. (2009) Türkiye elektrik tüketimini tahmin etmek için; yapay sinir ağlarıyla 1975-2006 yılları arasındaki verileri kullanarak 2027 yılına kadar elektrik tüketimini tahmin etmişlerdir. Ekonomik göstergelerden olan gayri safi milli hasıla, nüfus, ithalat ve ihracat fonksiyonlarını kullanarak elektrik tüketimini modellemişlerdir. İthalat- ihracat oranları ve sadece zaman girişleriyle de modellemeler yapmışlardır. Daha sonra mutlak ve yüzde hata karelerine dayanan modeller arasında performans karşılaştırması yaparak sonuçları değerlendirmişlerdir.

Toksarı (2009) Türkiye'nin net elektrik enerji üretimi ve talebini belirlemek için karınca kolonisi optimizasyon yaklaşımı kullanmıştır. 1979-2006 yılları arasındaki GSMH, nüfus, ithalat ve ihracat verileri kullanılarak karınca kolonisi optimizasyonu

elektrik tahmin modeli geliştirilmiştir. Burada önerilen bütün denklemler elektrik enerji üretimi ve talebi için lineer ve ikinci derecedendir. İkinci dereceden model elektrik enerji üretimi ve talebi için daha iyi sonuçlar verdiği için; bu model kullanılarak 2025 yılına kadarki elektrik enerji üretimi ve talep tahminleri gerçekleştirilmiştir.

Çınar ve ark. (2010) çalışmalarında Türkiye’de stratejik enerji çalışmalarında değişen enerji senaryolarına göre genetik algoritma (GA) kullanarak yeni model geliştirmişlerdir. 1970-2006 yılları arasındaki GSMH, yüklenmiş kapasite, nüfus, birincil enerji ve elektrik tüketimi verilerini kullanarak 2007-2012 yılları için hidroelektrik enerji talebini hesaplamışlardır.

Demirel ve ark. (2010) tahminleme yöntemlerinden Adaptif Ağ Tabanlı Bulanık Çıkarım Sistemi (ANFIS) ve otoregresif hareketli ortalama (ARMA) teknikleri ile elektrik enerjisi talep tahminleri yapılmış ve hangi yöntemin talep tahmininde daha başarılı olduğu ortaya konulmuştur. Bu çalışmada, 1970-2005 arası gayri safi milli hasıla , üretilen enerji, tüketilen enerji, nüfus ve kurulu güç verileri kullanılarak ANFIS ve ARMA modelleri oluşturulmuştur. Elde edilen model yardımıyla 2006-2010 yıllarına ait elektrik enerjisi talep tahminleri elde edilmiştir. ANFIS ve ARMA ile bulunan sonuçların karşılaştırmalı yorumları yapılarak önerilerde bulunulmuştur.

Erdoğan (2010) çalışmasında talep özelliklerine odaklanarak doğalgaz talebinin Türkiye’de kısa ve uzun vadede fiyat ve gelir esnekliğini dikkate alarak tahminlerini gerçekleştirmiştir. 1987-2007 yılları arasındaki doğal tüketim verileri ile ARIMA modelini kullanarak Türkiye’nin doğalgaz talebini 2008-2030 yılları arasında tahmin etmiş ve bu sonuçları resmi sonuçlarla karşılaştırmıştır.

Küçükali ve Barış (2010) Türkiye’nin elektrik enerjisini tahmin etmek için bulanık mantık metodolojisini kullanmışlardır. Türkiye’de birden fazla parametre kullanan elektrik enerjisi tahmin çalışmalarının aksine, sadece 1980-2008 yılları arasındaki GSMH parametresini kullanarak 2009-2014 yıllarındaki elektrik talebi tahmin

edilmiştir. Elde edilen tahminler ETKB'nin, literatürdeki regresyon modeli çalışmasının sonuçlarıyla karşılaştırılmış ve daha iyi sonuçlar verdiği saptanmıştır.

Filik ve ark. (2011) elektrik enerjisi talep tahmini için yeni bir matematiksel model geliştirmişlerdir. Yöntem uzun dönemli tahminler yapabilmektedir. 1982-2007 yıllarındaki uzun dönemli gerçek yıllık yük verileri kullanılmıştır. Birçok matematiksel fonksiyonlar, minimum tahmin hatasına ulaşabilmek için iç içe geçen sistemlerin her aşamasında kullanılır. Önerilen modelin tahmin doğruluğunu gösterebilmek için kök ortalama hata kareleri ve ortalama mutlak yüzde hata değerleri verilmiş ve doğru tahminlerin yapılabileceği ileri sürülmüştür.

Kankal ve ark. (2011) Türkiye'nin enerji tüketimini sosyo-ekonomik ve demografik değişkenler kullanarak tahmin etmişlerdir. Gayri safi yurtiçi hasıla, nüfus, ithalat-ihracat miktarları ve istihdam değişkenleriyle regresyon analizi ve yapay sinir ağlarını kullanarak 2008-2014 yılları Türkiye enerji tüketimi tahmin edilmiştir. Elde edilen tahmin sonuçları birbirleriyle ve resmi tahminlerle karşılaştırılarak sonuçlar ortaya konmuştur.

Kavaklıoğlu (2011) Türkiye'nin elektrik enerjisini tahmin etmek ve modellemek için destek vektör regresyon metodolojisini kullanmıştır. 1975-2006 yılları arasındaki GSYH, nüfus, ithalat ve ihracat verilerini kullanarak 2026 yılına kadarki talep tahminini gerçekleştirmiştir. Geliştirilen modellerden ortalama kök hata karelerine göre en iyi sonucu veren model seçilmiştir. Elde edilen sonuçlara göre bu model gelecek tahminler için kullanılabilir.

Bilgili ve ark. (2012) Türkiye'deki konut ve sanayi sektörlerinin enerji tüketimini tahmin etmek için YSA, lineer regresyon (LR) ve lineer olmayan regresyon (NLR) modellerini kullanmıştır. Kurulu kapasite, brüt elektrik üretimi, nüfus ve toplam abone sayısı değişkenleriyle yapılan hesaplamalar literatürde yapılan çalışmalar ve Enerji ve Tabii Kaynaklar Bakanlığı(ETKB)'ndaki sonuçlarla karşılaştırılmıştır. Bu karşılaştırmalar neticesinde YSA yöntemi LR ve NLR modellerden daha iyi sonuç verdiği mukayese edilmiştir.

Dilaver ve Hunt (2012) Türkiye'nin gelecek elektrik enerji talebini tahmin etmek için toplam elektrik enerji tüketimi, GSMH ve elektrik fiyatları arasındaki ilişkiyi araştırmışlardır. Bunu başarmak için, 1960-2008 yılları arasındaki veriler yapısal zaman serileri tekniklerine uygulanarak Türkiye'nin toplam elektrik talep fonksiyonu tahmin edilmiş ve 2020 yılına kadarki tahminler gerçekleştirilmiştir. Sonuçlara göre GSMH, elektrik fiyatları ve temel enerji talep trendi Türkiye elektrik enerji talebinde önemli etkenlerdir.

Kıran ve ark. (2012) çalışmalarında Türkiye'nin enerji talep tahmini için parçacık sürü ve karınca koloni optimizasyonuna dayanan bir model geliştirmişlerdir. Bu modelde GSYH, nüfus, ithalat ve ihracat değişkenlerini kullanmışlardır. Modeldeki ekonomik göstergelerin dalgalanmalarını karşılamak için iki form (lineer ve ikinci dereceden) geliştirilmiştir. 1979-2005 yılları arasındaki veri setleri kullanılarak 3 farklı senaryo için 2006-2025 yıllarındaki enerji talebi tahmin edilmiştir. Sonuçlar PSO ve ACO ile karşılaştırılmış ve yorumlanmıştır.

Türkiye'de enerji alanında gerçekleştirilen bazı önemli çalışmalar Çizelge 2.2 özetlenmiştir.

Çizelge 2.2. Türkiye’de enerji alanında yapılan çalışmalar

Yazarlar	Tahmin Yöntemi	Veri Yıl Aralığı	Enerji Türü	Tahmin yılı
Ceylan ve Öztürk (2004)	GA	1970-2001	Toplam Enerji	2002-2025
Hamzaçebi ve Kutay (2004)	YSA	1970-2002	Elektrik enerjisi	2003-2010
Sözen ve ark. (2004)	YSA	2000-2002	Solar enerji	Model kuruldu
Öztürk ve ark. (2004)	GA	1990-2000	Kullanılabilir petrol	2001-2020
Sözen ve ark. (2005)	YSA	1975-2003	Toplam enerji	Model kuruldu
Haldenbilen ve Ceylan (2005)	GA	1970-2000	Ulaştırma enerji	2001-2020
Ediger ve ark. (2006)	ARIMA	1950-2003	Fosil yakıtlar	2004-2028
Murat ve Ceylan (2006)	YSA	1970-2001	Ulaştırma enerji	2004,2005,2010-2020
Akay ve Atak (2007)	Gri Tahmin	1970-2004	Elektrik enerjisi	2006-2015
Ediger ve Akar (2007)	ARIMA	1950-2004	Toplam enerji	2005-2020
Sözen ve Arcaklıoğlu (2007)	YSA	1968-2005	Toplam enerji	Model kuruldu
Erkan (2007)	ARIMA	1984-2004	Elektrik enerjisi	2005-2014
Hamzaçebi (2007)	YSA	1970-2004	Elektrik enerjisi	2005-2020
Toksarı (2007)	ACO	1979-2005	Toplam Enerji	2006-2025
Canyurt ve Öztürk (2008)	GA	1975-2006	Fosil yakıt	2007-2020
Ünler (2008)	PSO	1979-2005	Toplam enerji	2006-2025
Kavaklıoğlu ve ark. (2009)	YSA	1975-2006	Elektrik enerjisi	2007-2027
Toksarı (2009)	ACO	1979-2006	Elektrik enerjisi	2007-2025
Çınar ve ark. (2010)	GA	1970-2006	Hidroelektrik	2007-2012
Demirel ve ark. (2010)	ANFIS	1970-2005	Elektrik enerjisi	2006-2010
Erdoğan (2010)	ARIMA	1987-2007	Doğal gaz	2008-2030
Küçükali ve Barış (2010)	Bulanık mantık	1980-2008	Elektrik enerjisi	2009-2014
Filiz ve ark. (2011)	Matematiksel model	1982-2007	Elektrik enerjisi	Model kuruldu
Kankal ve ark. (2011)	YSA, Regresyon	1980-2007	Toplam enerji	2008-2014
Kavaklıoğlu (2011)	Destek vektör regresyon modeli	1975-2006	Elektrik enerjisi	2007-2026
Bilgili ve ark. (2012)	YSA, Regresyon	1990-2007	Elektrik enerjisi	2008-2015
Dilaver ve Hunt (2012)	Yapısal zaman serileri	1960-2008	Elektrik enerjisi	2009-2020
Kıran ve ark. (2012)	Hibrit model (PSO ve ACO)	1979-2005	Toplam Enerji	2006-2025

3. YÖNTEM

3.1. Yapay Sinir Ağlarının Tanımı

YSA'nın herkes tarafından kabul edilen genel bir tanımı yoktur. Bazı bilim adamları tarafından yapılmış olan tanımlar aşağıdaki gibidir.

YSA bir sinir ağı, bilgiyi depolamak için doğal eğilimi olan basit birimlerden oluşan paralel dağıtılmış bir işlemcidir. YSA insan beynine iki açıdan benzemektedir. Bilgi, öğrenme işlemi yoluyla ağ tarafından elde edilir. Sinaptik ağırlıklar olarak bilinen nöronlar arası bağlantı kuvvetleri bilgiyi depolamak için kullanılır [Haykin, 1994].

YSA insan idrakinin ve biyolojik sinirlerin matematiksel modelinin genelleştirilmesi olarak da tanımlanabilir [Fausett, 1994].

YSA, klasik modelleme tekniklerinden yapısal ve kavramsal olarak oldukça büyük farklılıklar gösteren bir modelleme yöntemidir. YSA temelde, insan beyninin çalışma prensiplerinden esinlenilerek ortaya konmuş bir modelleme düşüncesidir. İnsan beyninin işleyişi üzerine yapılan nörofizyolojik çalışmalar 20. yüzyılın ortalarına kadar uzanmaktadır [Maier and Dandy, 2000].

YSA, birçok basit işlemci elemandan oluşan yapılardır. Bu elemanlar farklı formda ifade edilebilen nümerik verileri taşıyan “bağlantılar” veya “ağırlıklar” ile birbirine bağlıdırlar [Sağıroğlu ve ark., 2003].

YSA aynı zamanda, “bağlantılı ağlar (connectionist networks)”, “paralel dağıtılmış ağlar (parallel distributed networks)”, neuroformik sistemler (neuroformic systems)” olarak da adlandırılmaktadır. Yapay sinir ağları bilgisayar bilimine de bazı yenilikler getirmiştir. Algoritmik olmayan, adaptif, paralel programlama, dağıtılmış programlama vb. gibi tekniklerin gelişmesine katkıda bulunmuşlardır. Özellikle olaylar hakkında bilgilerin olmadığı fakat örneklerin bulunduğu durumlarda çok

etkin olarak kullanılabilecek bir karar verme aracı ve hesaplama yöntemi olarak görülebilir [Öztemel, 2003].

YSA'ndaki gelişmelerin temel kaynağı, beynimizin rutin olarak gerçekleştirdiği karmaşık hesaplamaları yapay, belki zeki davranış sergileyen sistemlerin yapılabilmesi ümididir [Sağıroğlu, 2003].

Bilgi işleme süreçleri olarak nitelendirebileceğimiz yapay sinir ağları verilen girdilere karşılık çıktılar üreten bir kara kutu olarak nitelendirilebilir. Yapay sinir ağları alışılmış bilgi işleme yöntemlerinden farklılık göstermektedir. Hatta sahip olduğu özelliklerden dolayı birçok yönetime göre daha sağlıklı sonuçlar üretmektedir [Şen, 2004].

3.2. Yapay Sinir Ağlarının Tarihçesi

İnsan beyni üzerindeki ilk çalışmalar çok eski zamanlara uzanmaktadır. Modern elektroninin gelişmesi ile birlikte, bu düşünce işlemi kullanmaya çalışmak doğal hale gelmiştir [Elmas, 2003].

Sinir ağları ile ilgili ilk çalışmalar, 19. yy'ın sonları ile 20. yy'ın başlarında görülmektedir. İlk çalışma; Helmholtz, Mach ve Pavlov gibi bilim adamları tarafından geliştirilen disiplinler arası (fizik, psikoloji ve nöropsikoloji) bir çalışmadır. Bu çalışmadaki amaç; öğrenme, sezme ve şartlanmanın genel teorisini vurgulamaktadır. YSH konusunda ilk çalışmalar 1940'lı yıllarda başlamıştır. 1943 yılında Warren McCulloch ve Walter Pitts, YSH'nin aritmetik ya da mantıksal bir fonksiyon için hesaplama yapabildiğini göstermiştir. McCulloch ve Pitts tarafından geliştirilen bu ilk model değişikliğe uğrayarak daha sonraki çalışmalarda genişçe kullanılmıştır [Hamzaçebi, 2011]. YSA ile ilgili önemli görülen çalışmalar kronolojik sırada Çizelge 3.1'de gösterilmektedir.

Çizelge 3.1. YSA ile ilgili yapılan çalışmaların kronolojisi[Hamzaçebi, 2011]

1938	Rashevsky, sinirsel alan teorisi olarak da bilinen nörodinamik çalışmalarını başlattı. Bu çalışmalarda sinir ağlarındaki aktivasyon ve yayılımın diferansiyel eşitlikler ile gösterimi bulunmaktadır.
1943	McCulloch ve Pitts, biyolojik sinir hücresinin ilk yapay modelini gösterdi.
1943	Landahl, McCulloch ve Pitts, birçok aritmetiksel ve mantıksal işlemin, McCulloch ve Pitts nöron modelini kullanan metotlar ile gerçekleştirilebileceğini ileri sürdü.
1949	Hebb, “Davranış Organizasyonu” isimli kitabını yazdı.
1954	Gabor, gözlenen sinyal ile geçmiş bilgiye dayalı üretilen sinyal arasındaki hataların kareleri ortalamalarını minimize edecek ağırlıkların belirlenmesinde dik iniş (gradient descent) algoritmasını kullanan öğrenme süzgecini icat etti.
1958	Rosenblatt, McCulloch ve Pitts nöron modeli için bir öğrenme metodu geliştirerek algılayıcıyı (perceptron) icat etti.
1960	Widrow ve Hoff, hata kareleri ortalamalarını minimize etmek üzere eğitilen basit bir ağ olan adaptif doğrusal eleman(ADALINE)’ı tanıttı.
1962	Rosenblatt, çok katmanlı ağların eğitimi için geri-yayılım hareket planını önerdi. Ancak bu öneri, türevlenemeyen fonksiyonlar kullandığı için başarısız oldu.
1967	Amari, kredi tayin problemlerinin çözümünde çok katmanlı ağlarda ağırlıklar için bir öğrenme kuralı belirlenmesinde bir matematiksel çözüm elde etti. Ancak bu buluşun önemi uzun bir süre fark edilemedi.
1969	Minsky ve Papert yayınladıkları kitapta basit algılayıcı modelinin sınırlarını gösterdi. Bu kitaptan sonra YSA konusundaki çalışmalar yavaşladı.

Bilim adamları, Minsky ve Papert’ın düşüncelerinden etkilendi ve YSA’yla yapılacak çalışmaların bittiğine inandı. Böylece Rosenblatt ve Widrow’un çalışmaları algılayıcı ve ADALINE gözden düştü. Aslında Rosenblatt ve Widrow bu sınırların farkındaydı ve bunları ortadan kaldıracak yeni ağlar önerdiler. Ancak karmaşık ağların eğitimini sağlayacak öğrenme algoritmasını geliştiremediler.

Böylece on yıl boyunca YSA çalışmaları büyük ölçüde ertelendi. Ancak 1970’li yıllarda az da olsa bazı çalışmalar yapıldı [Hagan, 1995].

YSA alanındaki çalışmalar, yeni düşüncelerin olmaması ve güçlü dijital bilgisayarların eksikliğinden dolayı 1960’ların sonlarında kesintiye uğramıştı. Ancak 1980’li yıllarda bu engellerin ortadan kalkması ile YSA konusunda çalışmalar artmaya başladı. Yeni kişisel bilgisayarlar ve iş istasyonları başarılı bir şekilde kullanılmaya başlandı ve yeni kavramlar geliştirildi. Özellikle iki yeni kavram YSA’nın yeniden doğuşunu sağlamıştır. Bunlardan biri John Hopfield’in çalışması, diğeri de Rumelhart ve arkadaşlarının çok katmanlı ağları eğitmede kullanılan Geri Yayılım Algoritmasının geliştirilmesidir [Hamzaçebi, 2011].

Hopfield ve Rumelhart’ın çalışmaları yapay sinir ağlarının genelleştirilebileceği ve özellikle geleneksel bilgisayar programlama ile çözülmesi zor olan problemlere çözüm üretebileceğini gösterdi. Bu nedenle de yapay sinir ağlarına olan ilgi tekrar artmaya başlamıştır [Haykin, 1994].

3.3. Yapay Sinir Ağlarının Özellikleri

YSA’nın bütün modeller için geçerli olan genel karakteristik özellikleri bulunmaktadır. Doğrusal olmayan yapıları modelleyebilmesi, farklı problemler için uyarlanabilirliği, öğrenme ve genelleme yapma yeteneği, paralel dağılmış yapısı, hata toleransına sahip olması en önemli özelliklerindendir. YSA’nın bu özellikleri işletme, finans, mühendislik, tıp vb. birçok farklı alanda tercih edilmelerini sağlamıştır. Aşağıda kısaca bu özelliklerden bahsedilmektedir.

3.3.1. Doğrusal olmama

YSA’yı meydana getiren yapay sinir hücreleri (YSH) için tercih edilen aktivasyon fonksiyonu sayesinde YSA’nın doğrusal ya da doğrusal olmayan modellemeyi gerçekleştirmesi sağlanır. Günlük yaşamda karşılaşılan birçok problemin doğrusal

olmayan ilişkiler içerdiği düşünüldüğünde YSA'nın bu özelliğinin önemi anlaşılabilir [Haykin, 1994].

3.3.2. Öğrenme

İnsan sinir sisteminin çalışmasını taklit eden YSA, problemin verileri kullanarak veri yapısındaki ilişkileri ortaya çıkararak ağın öğrenmesi sağlar. Öğrenme işlemi esasında YSA'yı meydana getiren YSH'leri arasındaki bağlantıların ağırlıklarının belirlenmesi işlemidir [Hamzaçebi, 2011].

3.3.3. Genelleme

YSA'nın, eğitildikten sonra eksik bilgiler ile çalışabilir ve gelen yeni örneklerde eksik bilgi olmasına rağmen sonuç üretebilir. Geleneksel sistemlerin aksine eksik bilgiyle de çalışmaya devam ederler [Öztemel, 2003].

3.3.4. Uyarlanabilirlik

Belirli bir problem için eğitilen YSA, problem farklılaştığında yeni probleme göre uyarlanabilir ve yeniden eğitilebilir [Hamzaçebi, 2011].

3.3.5. Hata toleransı

YSA'nın eksik bilgilerle çalışabilmesi hatalara karşı toleranslı olmalarını sağlamaktadır. Ağın bir takım hücrelerinin bozulması ve çalışamaz duruma düşmesi halinde ağ çalışmaya devam eder. Ağın bozuk olan hücrelerinin sorumluluklarının önemine göre performansında düşmeler görülebilir. Hangi hücrelerinin sorumluluklarının önemli olduğuna da yine ağ eğitim esnasında kendisi karar verir. Bunu kullanıcı bilmemektedir. Ağın bilgisinin yorumlanamamasının nedeni de budur [Öztemel, 2003].

3.4. Yapay Sinir Ağlarının Avantajları ve Dezavantajları

Yapay sinir ağlarının en büyük avantajı, öğrenme kabiliyetinin olması ve farklı öğrenme algoritmaları kullanabilmesidir. Yapay sinir ağları uyarlanabilir ve esneyebilir. Tek bir yapay sinir ağı, herhangi bir işleve ilke olarak yaklaşabilir. Yapay sinir ağlarını yapısını ve öğrenme kuralını değiştirmek zorunda değiliz, sadece öğretim materyalini değiştirerek öğrenmeyi sağlayabiliriz. Bunlara karşılık dezavantajları ise sistemin çalışmasının analiz edilememesi ve öğrenme işleminde başarılı olunama riski olmasıdır [Duman, 2006].

3.4.1. Avantajları

- Matematiksel modele ihtiyaç duymazlar.
- Öğrenme kabiliyeti vardır ve farklı öğrenme algoritmalarıyla öğrenebilirler.
- Matematiksel olarak modellenmesi zor olan ya da mümkün olmayan problemleri rahatlıkla çözümleyebilir.
- Bir problem için ağ modelleneneceği zaman herhangi bir bilgiye ihtiyaç duyulmaz sadece örnek gereklidir. Örnek bulmaksa bilgi bulmaktan kolaydır.
- Gerçek hayatta olaylar ve olayların arkasındaki değişik etkenlerin birbiri ile ilişkilerini bilmek zordur. Ancak bu yapay sinir ağları ile otomatik olarak yapılır.
- YSA'nın uygulanması oldukça pratik ve ekonomiktir. Sadece probleme ilişkin örneklere ihtiyaç duyulduğundan basit bir programlama ile problemin çözümü mümkün olabilmektedir.
- YSA diğer sistemlere oranla zaman bakımından da verimli olup, örnek bulunduğu, probleme uygun ağ oluşturularak, ağın öğrenmesi ve diğer örnekler içinde kullanılabilmesi çok kısa zamanda yapılabilir.
- YSA, aynı olay için yeni ve farklı bilgiler oluşturduğunda da yeniden rahatlıkla eğitilebilir ve ortama uyum sağlaması sağlanabilmektedir.
- YSA paralel olarak çalıştığı için gerçek-zamanlı uygulamalar için kullanımı kolaydır.

3.4.2. Dezavantajları

- Sistem çalışırken içerisinde neler olduğu bilenememektedir.
- Farklı sistemlere uygulanması zaman zaman zor ve güç olabilmektedir.
- YSA ile bir uygulama geliştirilirken model seçiminde ve ağların topolojisini belirlerken belli bir kural yoktur. Doğru seçimlerin yapılması tamamen kullanıcının tecrübesine bağlıdır.
- Herhangi bir problemin çözümünde kullanılmak üzere ağa sunulacak olan örnekler toplanırken de bir kural durumu yoktur, kullanıcı kendisi örnekleri belirler ve formülize eder.
- Ağın davranışlarının açıklanması mümkün olmadığı için ağa güven azalmaktadır.
- Bazen eğitim gerçekleşmesi uzun zaman alabilir.
- Bulunan çözümün en uygun çözüm olduğunu söylemek mümkün değildir. Sadece iyi çözümlerden biri olduğu söylenebilir. Oysa geleneksel yöntemler en uygun sonuçlar üretebilirler.
- Örneklerin bulunmasının zor olduğu ya da doğru örnekler için karar verilmediği durumlarda sağlıklı çözüm üretilememektedir.

3.5. Yapay Sinir Ağları'nın Uygulama Alanları

Yapay sinir ağları üzerinde binlerce uygulama yapılmış ve başarılı sonuçlar üretmiştir. Geniş bir uygulama alanına sahiptir. Temel olarak yapay sinir ağları uygulamaları ile aşağıdaki işlemler yapılmaktadır [Duman, 2006]:

Tahmin: Ağa sunulan giriş değerlerine karşılık çıkış değerlerini tahmin edebilirler.

Sınıflandırma: Kendilerine sunulan bilgileri kategorize ederler.

Veri ilişkilendirme: Ağlar, ağa sunulan verilerin hatalı ya da eksik olup olmadığını belirler. Eksik bilgi varsa tamamlar.

Veri filtreleme: Ağlar birçok veri arasından uygun verileri bulurlar.

Tanıma ve eşleştirme: Değişik şekil ve örüntülerin tanınması, eksik, belirsiz bilgilerin eşlenmesi işlemini yaparlar.

Teşhis: Ağlar sistemlerin olumsuzluklarını ortaya çıkarır ve problemlerin teşhis edilmesini sağlar.

Yorumlama: Bir olay hakkında toplanan verilerle ağ eğitildikten sonra bu bilgileri kullanarak yeni olayları yorumlarlar.

Yukarda verilen fonksiyonları gerçekleştiren yapay sinir ağları çok farklı alanlarda kullanılmaktadır. YSA'lar sadece bir mühendislik tekniği değildir. Fen bilimleri, matematik, tıp, işletme, finans, istatistik vb. birçok alanda YSA yardımı ile çözülmüş oldukça fazla problem vardır. Literatürde binlerce makale YSA'ların farklı disiplinlerde kullanılmasına yönelik teorik ve uygulama çalışmalarını konu edinmiştir [Hamzaçebi, 2011].

YSA ayrıca ses tanıma, el yazısı tanıma, parmak izi tanıma, otomatik araç denetimi, fizyolojik işaretleri (kalp fonksiyonları vs.) izleme, tanıma ve sınıflandırma gibi alanlarda da kullanılmaktadır [Elmas, 2007].

3.6. Yapay Sinir Ağlarının Yapısı ve Temel Bileşenleri


3.6.1. Biyolojik sinir hücresi

Beynin çalışma sistemi, hala tam olarak çözülememiş bir sırdır. Özellikle, vücudun diğer organlarındaki hücrelerden farklı olarak yenilenebilme özelliği olmayan beynin, insana hatırlama, düşünme ve her hareketinde geçmiş deneyimlere başvurma yeteneğini sağlayan en temel elemanı olan sinir hücrelerinin çalışma sistemi hala gizliliğini büyük ölçüde korumaktadır. İnsan beyinde ortalama 100 milyar sinir hücresi ve her bir sinir hücresinin 1.000 ile 10.000 arası komşu bağlantısı vardır.

Beynin gücü bu çok sayıdaki sinir hücresi ve aralarındaki sonsuz sayıdaki bağlantılardan, genetik yapıları ile öğrenme yeteneklerinden kaynaklanmaktadır.

Biyolojik sinir sistemi, merkezinde sürekli olarak bilgiyi alan, yorumlayan ve uygun bir karar üreten beynin bulunduğu üç katmanlı bir sistem olarak açıklanmaktadır. Bu katmanlar; çevreden gelen girdileri elektriksel sinyallere dönüştürerek beyine ileten alıcı sinirler (Receptor), beynin ürettiği elektriksel sinyalleri çıktı olarak uygun tepkilere dönüştüren Tepki sinirleri ile alıcı ve tepki sinirleri arasında ileri ve geri besleme yaparak uygun tepkiler üreten merkezi sinir ağı olarak sıralanır [Baş, 2006].

Beyin, sıkışık olarak ara bağlaşımlı milyarlarca nörondan oluşmaktadır. Her eleman kendi aralarında oldukça çok sayıda nörona (eleman başına yaklaşık olarak 104 bağlantı) bağlanmıştır. Bir nöronun aksonu (çıkış yolu) ayrıştırılmıştır ve bir sinaps olarak adlandırılan bir jonksiyon vasıtasıyla diğer nöronların dendritlerine bağlanmıştır. Bu jonksiyon uçlarındaki iletim doğal olarak kimyasaldır ve işaretin miktarı, akson tarafından serbest bırakılan kimyasalların büyüklüğüne bağlı olarak transfer edilir ve dendritler vasıtasıyla alınır. Bu sinaptik büyüklük, beyin öğrenirken neyin modifiye edildiğini belirtir. Bu sinaps, beynin temel hafıza mekanizmasına dayanarak nöron içerisindeki bilginin islenmesi ile birleştirilir [Duman, 2006].



Şekil 3.1. Sinir Hücresi [Freeman ve Skapura, 1991]

Verilen özellikte milyarlarca sinir hücresi bir araya gelerek sinir sistemini oluşturmaktadır. YSA'lar, insan beyninin çalışma prensibi örnek alınarak geliştirilmeye çalışılmıştır ve aralarında yapısal olarak bazı benzerlikler vardır. Bu benzerlikler Çizelge 3.2'de ve istatistiksel prensiplerle yapay sinir ağları arasındaki terminolojik ilişkiler de Çizelge 3.3 de verilmiştir.


Çizelge 3.2. Sinir sistemi ile YSA'nın benzerlikleri [Sağıroğlu ve ark., 2003].

Biyolojik Sinir Sistemi	Yapay Sinir Ağları
Sinir Sistemi	Sinirsel Hesaplama Sistemi
Nöron (Sinir)	İşlem Elemanı
Dendrit	Toplama Fonksiyonu
Hücre Gövdesi	Aktivasyon Fonksiyonu
Aksonlar	Eleman Çıkışı
Sinapslar	Ağırlıklar

Çizelge 3.3. İstatistiksel yöntemlerle yapay sinir ağlarının benzeşimleri

İstatistiksel	Yapay Sinir Ağları
Model	Ağ
Tahmin	Öğrenme
Regresyon	Öğretmenli Öğrenme
İnterpolasyon	Genelleştirme
Gözlem	Öğrenme Algoritması
Parametre	Ağ Parametreleri (ağırlıklar, katsayılar)
Bağımsız Değişken	Giriş Verileri
Bağımlı Değişken	Çıkış Verileri
Sınır Regresyon	Ağırlık Budama İşlemi

Biyolojik sinir ağlarının yapay sinir ağlarına bir dayanak olduğu şematik olarak Şekil 3.2’de gösterilmiştir.



Şekil 3.2. Biyolojik ve yapay sinir ağları [Öztemel, 2003]


3.6.2. Yapay sinir hücresi

Yapay Sinir Hücresi (YSH), insan sinir hücresini taklit etmeye yönelik bir girişimin sonucudur. Bir yapay sinir hücresi Şekil 3.3’te görüldüğü gibi genel olarak beş temel bileşenden oluşmaktadır.

- Girdiler
- Ağırlıklar
- Toplama fonksiyonu

- Aktivasyon fonksiyonu
- Çıktı

Girdiler sinir hücresine girdikten sonra ilgili bağlantı ağırlıkları ile çarpılırlar, daha sonra bir birleştirme fonksiyonu (genellikle toplama fonksiyonu) ile birleştirilirler ve böylece nöronun net girdisi elde edilir. Net girdi bir aktivasyon fonksiyonu tarafından işlenir. Aktivasyon fonksiyonunun çıktısı ise nöronun net çıktısını tayin eder [Hamzaçebi, 2011].



Şekil 3.3. Yapay sinir hücresi

Girdiler

Girdiler, bir yapay sinir hücresine gelen bilgilerdir. Bu bilgiler dış ortamlardan ya da diğer sinir hücrelerinden gelebilir. Dış ortamlardan gelen bilgiler, ağız öğrenmesi istenen örnekler tarafından belirlenmektedir [Öztemel, 2003].

Ağırlıklar

Ağırlıklar, gelen bilgilerin hücre üzerindeki etkisini belirleyen katsayılardır. Bilgiler, bağlantılar üzerindeki ağırlıklar üzerinden hücreye girmekte ve ağırlıklar yapay sinirde girdi olarak kullanılacak değerlerin göreceli kuvvetini (matematiksel katsayısını) göstermektedirler. Yapay sinir ağı içinde girdilerin hücreler arasında iletimini sağlayan tüm bağlantıların farklı ağırlık değerleri bulunur [Elmas, 2007].

Toplama fonksiyonu

Toplama fonksiyonu, hücreye gelen net girdiyi hesaplayan fonksiyondur ve genellikle girişlerin kendi ağırlıklarıyla çarpımının toplamı;

$$Net\ Girdi_j = \sum_i w_{ij}x_i + w_{0j} \quad [3.1]$$

biçiminde ifade edilir. Yapay sinir ağının yapısına göre toplama fonksiyonu, maksimum, minimum, çarpım veya çeşitli normalizasyon işlemlerinden birisi olarak da ifade edilebilir. Bir problem için en uygun toplama fonksiyonu çeşidini bulmak için herhangi bir formül yoktur. Toplama fonksiyonu genellikle deneme yanılma yoluyla bulunmaktadır. Ayrıca bir yapay sinir ağındaki bütün işlemci elemanların aynı toplama fonksiyonuna sahip olması gibi bir zorunluluk da yoktur. Bazen aynı yapay sinir ağı içindeki işlemci elemanların bazıları aynı toplama fonksiyonunu, diğerleri ise başka fonksiyonları kullanabilirler. Bu tamamen tasarımcının kendi kararına bağlıdır [Öztemel, 2003].

Çizelge 3.4. Toplama fonksiyonu örnekleri [Öztemel, 2003].

Toplama İşlemi	Açıklama
<i>Çarpım</i> Net girdi = $\prod_i x_i w_i$	Önce girdiler ve ağırlıklar, sonrada bu değerler birbirleriyle çarpılır.
<i>Maksimum (En çok)</i> Net girdi = $\text{Max}(x_i w_i), i = 1, 2, \dots, N$	N adet girdi ve ağırlıklar birbiriyle çarpıldıktan sonra en büyük değer net girdi olarak kabul edilir.
<i>Minimum (En az)</i> Net girdi = $\text{Min}(x_i w_i), i = 1, 2, \dots, N$	N adet girdi ve ağırlıklar birbiriyle çarpıldıktan sonra en küçük değer net girdi olarak kabul edilir.
<i>Çoğunluk</i> Net girdi = $\sum_i \text{sgn}(x_i w_i)$	N adet girdi ve ağırlıklar birbirleriyle çarpıldıktan sonra pozitif ve negatif olanların sayısı bulunur. Bunlardan büyük olan net girdi olarak alınır.
<i>Kümülatif Toplam</i> Net girdi = Net (eski) + $\sum_i (x_i w_i)$	Hücreye gelen bilgiler ağırlıklı olarak olarak toplanır ve daha önce gelen bilgilere eklenerek hücrenin net girdisi bulunur.

Aktivasyon fonksiyonu

Nöron davranışını belirleyen en önemli faktörlerden biri, nöronun aktivasyon fonksiyonudur. Aktivasyon fonksiyonu, toplama fonksiyonundan gelen girdiyi işleyerek yapay sinir hücresinin çıkışını belirler. Transfer fonksiyonu olarak da adlandırılan aktivasyon fonksiyonu çeşitli tiplerde ve genellikle doğrusal olmayan bir fonksiyondur. Doğrusal fonksiyonların tercih edilmemesinin nedeni, doğrusal fonksiyonlarda girdi ile çıktının doğru orantılı olmasıdır. Bu durum ilk yapay sinir ağları denemelerinin başarısızlıkla sonuçlanmasının temel nedenidir. Aktivasyon fonksiyonu olarak en çok kullanılanlar sigmoid fonksiyon ve hiperbolik tanjant fonksiyonlarıdır.


Aktivasyon fonksiyonu, toplama fonksiyonundan gelen girdiyi dönüştürerek istenilen değerler arasında sınırlandırmaktadır. Bu nedenle bazı kaynaklarda sıkıştırma veya eşik fonksiyonu olarak da adlandırılmaktadır. Bu değerler kullanılan aktivasyon fonksiyonun tipine göre genellikle $[0,1]$ veya $[-1,1]$ arasındadır [Hamzaçebi, 2011].

Aktivasyon fonksiyonu işlemi öncesinde, sisteme tekdüze (uniform) dağılmış bir rassal hata eklenebilmektedir. Bu rassal hatanın kaynağı ve büyüklüğü sistemin öğrenme sürecinde belirlenir ve sebebi, insan beyninin işlevinin, içinde bulunduğu ortamın koşullarından etkilenmesidir. Örneğin ortamın soğuk/sıcak olmasından insan beyni etkilenmektedir. Bu nedenle yapay sinir ağları literatüründe rassal hata ekleme işlemi "sıcaklık (temperature)" olarak da adlandırılmaktadır. Ancak günümüzde rassal hata işlevi tam olarak kullanılmamakta ve hala bir araştırma süreci içinde bulunmaktadır. Ayrıca bazı yapay sinir ağlarında, aktivasyon fonksiyonunun çıktısı üzerinde başka işlemler, ölçeklendirme ve sınırlandırma yapılabilmektedir [Baş, 2006].

Yapay sinir hücrelerinde yaygın olarak kullanılan çeşitli aktivasyon fonksiyonları aşağıda verilmiştir.

Doğrusal (özdeşlik) aktivasyon fonksiyonu

Doğrusal problemlerin çözümünde kullanılan bu fonksiyon, gelen net girdileri doğrudan hücre çıkışı olarak vermektedir. Matematiksel olarak $g(x)$ şeklinde tanımlanmaktadır [Hagan, 1996].




Şekil 3.4. Doğrusal aktivasyon fonksiyonu

Basamak fonksiyonu

Gelen net girdi değerinin belirlenen bir eşik değerinin altında ya da üstünde olmasına göre hücrenin çıktısı 1 veya 0 değerlerini almaktadır [Hamzaçebi, 2011].

$$g(x) = \begin{cases} b & x \geq c \\ a & x < c \end{cases} \quad [3.2]$$

Genellikle $c=0$, $a=0$, $b=1$ ya da $c=0$, $a=-1$, $b=1$ tercih edilir.




Şekil 3.5. Basamak Fonksiyonu

Sigmoid aktivasyon fonksiyonu

Sigmoid aktivasyon fonksiyonu, türevi alınabilir, sürekli ve doğrusal olmayan bir fonksiyon olması nedeniyle uygulamada en çok kullanılan aktivasyon fonksiyonudur. Bu fonksiyon, net girdinin her değeri için 0 ile 1 arasında bir değer üretmektedir ve formülü şu şekildedir [Haykin, 1994].

$$g(x) = \frac{1}{1 + e^{-x}} \quad [3.3]$$




Şekil 3.6. Sigmoid fonksiyonu

Hiperbolik tanjant fonksiyonu

Hiperbolik tanjant fonksiyonu, gelen net girdinin tanjant fonksiyonundan geçirilmesi ile hesaplanmaktadır ve sigmoid aktivasyon fonksiyonunun farklı bir çeşididir. Sigmoid aktivasyon fonksiyonunda çıktı 0 ile 1 arasında bir değer alırken, hiperbolik tanjant fonksiyonunda çıktı -1 ile 1 arasındadır ve şu şekilde hesaplanır [Hamzaçebi, 2011].

$$g(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad [3.4]$$




Şekil 3.7. Hiperbolik Tanjant Fonksiyonu

Hücrenin çıktısı

Aktivasyon fonksiyonu tarafından belirlenen çıktı değeridir. Bu değer ya başka bir yapay sinir hücresine girdi olarak ya da dış ortama gönderilmektedir. Bir işlemci elemanın birden fazla girdisi olmasına rağmen tek bir çıktısı olmaktadır.

3.6.3. Yapay sinir hücresinin çalışma prensibi

Şekil-3.8’de girişleri ve ağırlıkları verilmiş olan bir yapay sinir hücresinin çalışması şöyledir:



Şekil 3.8. Bir yapay sinir ağının çalışması örneği.

Hücreye gelen net girdi, ağırlıklarla girişler çarpılarak aşağıdaki gibi hesaplanır.

$$NET\ Girdi = 0.8 * 0.3 + 0.4 * (-0.3) + 0.3 * 0.2$$

$$NET\ Girdi = 0.24 - 0.12 + 0.06$$

$$NET\ Girdi = 0.18$$

Hücrenin sigmoid tipli aktivasyon fonksiyonuna göre çıkışı $y=g(x)$ şöyledir;

$$y = g(x) = 1 / (1 + e^{-0.18})$$


$$y = 0.54$$

Sonuçta verilen girdilere karşılık yukarıda işlemler sonucunda y çıkış değeri bulunur.

3.6.4. Yapay sinir ağı yapısı

Yapay sinir hücreleri bir araya gelerek yapay sinir ağını meydana getirmektedir. Yapay sinir hücrelerinin bir araya gelmesi rastgele değildir. Yapay sinir hücrelerinin genellikle birbiriyle bağlantılı 3 katman halinde ve her katman içinde birbirine paralel olacak şekilde bir araya gelerek ağı oluşturdukları görülür. Bu 3 katman, girdi katmanı (input layer), gizli katman (hidden layer) ve çıktı katmanı (output layer) olarak adlandırılır.

Girdi katmanı, dış ortamdan bilgileri alarak gizli katmanlara iletmekle görevlidir. Bazı yapay sinir ağlarında bu katmanda herhangi bir bilgi işleme olmamaktadır. Gizli katman, girdi katmanından gelen bilgileri işleyerek çıktı katmanına iletmekle görevlidir. Gizli katman olarak da adlandırılan gizli katman birden fazla olabilmektedir. Gizli katmanlar çok sayıda yapay sinir hücresi içermektedirler ve bu hücreler yapay sinir ağı içindeki diğer hücrelerle bağlantılıdır. Çıktı katmanı, gizli katmandan gelen işlenmiş bilgileri dış ortama aktarmakla görevlidir.



Şekil 3.9. Çok katmanlı bir yapay sinir ağı [Hamzaçebi, 2011]

3.6.5. Yapay sinir ağlarının eğitimi ve testi

Yapay sinir ağlarında bağlantıların ağırlık değerlerinin değiştirilmesi işlemine "ağın eğitilmesi" denilmektedir. Başlangıçta rastgele atanan bu ağırlık değerleri, ağa gösterilen örneklerle değiştirilmektedir. Amaç, ağa gösterilen örnekler için doğru çıktıları üretecek ağırlık değerlerinin belirlenmesidir.

Yapay sinir ağlarının eğitim süreci, belli kurallar çerçevesinde olmaktadır. Bu kurallara öğrenme kuralları adı verilmektedir. Ağırlıkların değiştirilmesi öğrenme kurallarına göre yapılır. Yapay sinir ağında ağırlıkların doğru değerlere ulaşması, örneklerin temsil ettiği problem konusunda ağın *genellemeler* yapabilme yeteneğine kavuşması demektir. Ağın bu genelleştirme özelliğine kavuşması işlemine "ağın öğrenmesi" denilir.


Yapay sinir ağlarında öğrenme iki aşamada gerçekleşir. Birinci aşamada ağa gösterilen örnek için ağın üreteceği çıktı belirlenir. Bu çıktı değerinin doğruluk derecesine göre, ikinci aşamada ağın bağlantılarının sahip olduğu ağırlıklar değiştirilmektedir. Ağın çıktısının belirlenmesi ve ağırlıkların değiştirilmesi öğrenme kuralına bağlı olarak farklı şekillerde olmaktadır.

Bir yapay sinir ağının eğitiminin tamamlanmasının ardından, ağın öğrenip öğrenmediğini (performansını) ölçmek için denemeler yapılarak ağın test edilmesi gerekmektedir. Bir ağı test etmek için ağın eğitimi sırasında görmediği, yani veri setinden test amaçlı olarak ayrılan örnekler kullanılır ve bu örnekler test kümesi adını alır. Test işleminde ağın ağırlık değerleri değiştirilmemektedir. Örnekler ağı gösterilmekte ve ağ eğitimi sırasında belirlenen ağırlık değerlerini kullanarak daha önce görmediği bu örnekler için çıktılar üretmektedir. Elde edilen çıktıların doğruluk dereceleri ağın öğrenmesi hakkında bilgi vermektedir. Sonuç ne kadar iyi olursa eğitimin performansı da o kadar iyi demektir (Öztemel, 2003).

3.7. Yapay Sinir Ağlarının Sınıflandırılması

Ağ topolojisi, yapay sinir ağlarında işlemci elemanlar arasındaki bağlantının şeklidir. Yapay sinir ağları için iki genel topoloji bulunmaktadır; ileri beslemeli (feed-forward) ve geri beslemeli (feedback) veya yinelemeli (recurrent) [Baş, 2006].


Birçok YSA türü vardır. YSA'lar, tiplerine, katman sayılarına, yapılarına ve öğrenme algoritmalarına göre sınıflandırılabilirler. Şekil 3.10 bu sınıflandırmayı göstermektedir.



Şekil 3.10. YSA'ların sınıflandırılması [Hamzaçebi, 2011].

3.7.1. Tipine göre YSA'lar

YSA'lar nöronlar arasındaki bağlantıların yapısına göre ileri beslemeli ve geri beslemeli olmak üzere iki sınıfta incelenirler. İleri beslemeli ağlarda veriler, girdi biriminden çıktı birimine ileri doğru akış göstermektedir. Bu ağ yapısında (Şekil 3.3) geri besleme yoktur. Geri beslemeli ağlarda ise veri akışı sadece ileriye doğru değil geriye doğru da olmaktadır. Bu ağ yapısında (Şekil 3.11), ağ çıktısı aynı zamanda girdi olarak da kullanılabilir.



Şekil 3.11. Geri Beslemeli Ağ Yapısı [Hamzaçebi, 2011].

3.7.2. Öğrenme yöntemine göre YSA'lar

YSA'nın en temel özelliği öğrenme yeteneğidir. Öğrenme YSA'nın içinde bulunduğu çevre tarafından uyarılması yani eğitilmesi sürecinde ağırlıklarını düzenlemesi işlemidir. Ağırlıkların düzenlenmesi işlemleri üç noktaya işaret etmektedir [Haykin, 1994].

1. YSA içinde bulunduğu çevre tarafından uyarılmaktadır.
2. Bu uyarıların sonucu YSA, ağırlıklarında bazı değişiklikler yapmaktadır. Bu değişiklik önceden belirlenmiş bazı kurallara göre gerçekleşir.
3. YSA içyapısındaki değişikliklerin sonucu olarak çevresine bir çıktı verir.


YSA'nın veri yapısındaki ilişkiyi öğrenmesini, probleme ait örnekler yardımı ile ağ ağırlıklarının en uygun değerlerinin belirlenmesi olarak tanımlayabiliriz. Herhangi bir ağırlık (w) için;

$$w_{yeni} = w_{eski} + \Delta w \quad [3.5]$$

denklemini, öğrenmenin matematiksel olarak nasıl gerçekleştiğini ifade etmektedir. Eş. 3.5'deki Δw değeri belli bir kurala göre hesaplanarak mevcut ağırlık değerlerinin değişim miktarını verir. Δw 'yi belirlemek için tanımlanmış kurallara öğrenme algoritmaları denir. En iyi ağırlık kümesini bulmaya yardım eden birçok öğrenme algoritması ileri sürülmüştür. Bu algoritmalar kabaca üç sınıfta incelenebilir: Öğretmenli, öğretmensiz ve destekleyici öğrenme algoritması [Haykin, 1994].

Öğretmenli öğrenme

Bu tip öğrenmede ağın eğitimi için çıktıların istenen değerleri ağa tanıtılabilmektedir. Girdi ve çıktı kümeleri ağa verilir. Ağ, girdiyi işleyerek kendi çıktısını üretir ve gerçek çıktı ile karşılaştırır, öğrenme metodu sayesinde, mevcut hatayı en aza indirmek için bağlantılardaki ağırlıklar yeniden düzenlenir. Bu işlem kabul edilebilir bir hata seviyesine ulaşıncaya kadar devam eder. Şekil 3.12, öğretmenli öğrenme algoritmasını göstermektedir. Algılayıcı, geri yayılım ağı ve Boltzmann makinesi en yaygın kullanılan öğretmenli ağlardır [Hamzaçebi, 2011] .



Şekil 3.12. Öğretmenli öğrenme [Hamzaçebi, 2011].

Öğretmensiz öğrenme

Ağın öğrenmesine yardımcı olan herhangi bir öğretmen yoktur. Yani çıktıların istenen değerleri ağa tanıtılamıyorsa, bu tip öğrenme şekli öğretmensiz öğrenme olarak adlandırılır. Hem çıktı hem de girdi olan veriler arasındaki kural ve ilişkilerin araştırılması ve en uygununun bulunması ağın eğitilmesi anlamına gelmektedir. Adaptif Rezonans Teorisi (ART), Hopfield Ağı, Kohonen Ağı en çok kullanılanlarıdır [Öztemel, 2003].

Destekleyici öğrenme

Öğretmenli öğrenme sisteminde olduğu gibi ağa bir öğretmen yardımcı olur. Ancak burada öğretmen, olması gereken çıktıları sisteme tanıtmaz. Bu sınıflandırma problemlerinde kullanılan öğrenme yöntemidir. Lineer Vektör Parçalama (LVQ) destekleyici öğrenme için örnek verilebilir [Bayır, 2006].

3.7.3. Yapısına göre YSA'lar

YSA'lar yapılarına göre otoasosyatif ve heteroasosyatif olmak üzere iki sınıfta incelenebilir. Otoasosyatif ağlar, girdi nöronlarının aynı zamanda çıktı nöronu olarak görev yaptığı ağlardır. Hopfield ağları bu türdendir. Heteroasosyatif ağlar, farklı girdi

ve çıktı nöronlarının bulunduğu ağ yapılarıdır. Algılayıcı, çok katmanlı algılayıcı, Kohonen ağı bu türdendir [Mehrotra ve ark., 1997].

3.7.4. Katman sayılarına göre YSA'lar

YSA'lar, YSH'nin oluşturduğu bir yapıdır. Benzer özellikleri gösteren YSH'nin oluşturduğu öbeğe katman denir. Örneğin girdi sinir hücreleri girdi katmanını, çıktı sinir hücreleri çıktı katmanını oluşturur. Eğer bir YSA tek katmandan oluşuyor ise tek katmanlı YSA, birden fazla katmandan oluşuyor ise çok katmanlı YSA olarak adlandırılır.

3.8. Çok Katmanlı Algılayıcı

Çok katmanlı algılayıcılar (ÇKA); ileri beslemeli ağlardan olup, öğrenme yöntemlerinden öğretmenli öğrenmeyi kullanan ağlardır. Heteroasosyatif YSA yapısına sahip olan ÇKA birden fazla katmana sahiptir.

ÇKA, doğrusal olmayan problemleri çözebilmeleri nedeniyle günümüzde geniş kullanım alanları bulan en popüler yapay sinir ağıdır. Ayrıca kullandığı öğrenme algoritması nedeniyle geri yayılım ağı olarak da anılmaktadır.

Yapay sinir ağlarına olan ilginin tekrar artmasına neden olan çok katmanlı algılayıcılar, başlangıçta akademik çevrelerin ilgisini çekerek üzerinde yapılan çalışmaları yoğunlaştırmış, daha sonra mühendislik problemlerinin hemen hepsine çözüm üretebilecek bir güce sahip olması nedeniyle endüstriyel alanda yoğun bir şekilde kullanılmaya başlanmıştır.


ÇKA'nın diğer YSA türlerine göre ayırt edici 3 özelliği bulunmaktadır [Haykin,1994].

1. Ağdaki her bir nöron doğrusal olmama özelliği içerir. Doğrusal olmama biçimi genellikle kullanılan sigmoid (lojistik) fonksiyonu ile sağlanır.

2. Gizli nöronlardan oluşan bir ya da daha fazla gizli katmana sahiptir. Gizli nöronlar, girdi verisi yapısındaki karmaşık yapıyı öğrenmede ağı başarılı kılarlar.
3. Ağ bağlantılar sayesinde çok yüksek derecede bilgi işleme becerisi gösterir. Ağın bilgi işleminde değişiklik olabilmesi, bağlantı sayısında ya da ağırlıklarında değişikliği gerektirir.

ÇKA, öğretmenli öğrenme metodunu kullanmaktadır. Ağın öğrenbilmesi için eğitim kümesi adı verilen ve örneklerin bir kısmından oluşan bir sete ihtiyaç vardır. Bu set içinde her örnek için hem girdiler hem de o girdiler için ağın üretmesi gereken çıktılar belirlenir. Öğrenme sırasında her örnek için ağın çıktı değeri ile beklenen çıktı değeri karşılaştırılır ve hata değeri ağı tekrar geri besleme şeklinde verilir. Örnek setindeki hata kareleri toplamını azaltmak için işlemci elemanlar arasındaki bağlantı ağırlıkları değiştirilmektedir.

Bir yapay sinir ağının geri yayılım yoluyla eğitilmesi; ileri doğru hesaplama ve geriye doğru hesaplama olmak üzere iki aşamadan oluşur.



Şekil 3.13. İleri beslemeli geri yayılım yapay sinir ağı yapısı

İleri doğru hesaplama, ağırlık çıkartısını hesaplama aşamasıdır. Bilgi işleme, girdi setindeki bir örneğin ağırlık gösterilmesi ile başlamaktadır. Daha önce de değinildiği gibi, girdi katmanında herhangi bir bilgi işleme gerçekleşmemektedir. Gelen girdiler hiç bir değişiklik yapılmadan gizli katmana gönderilir. Bu durum $y_k^i = x_k$ eşitliği ile gösterilebilir.

Gizli katmandaki her işlemci eleman, girdi katmanındaki bütün işlemci elemanlardan gelen bilgileri bağlantı ağırlıklarıyla ağırlıklandırarak alır. Önce gizli katmandaki işlemci elemanlara gelen net girdi;

$$s_j^a = \sum_{k=1}^n w_{jk} y_k^i \quad [3.6]$$

ile hesaplanır.

Burada w_{jk} , k . girdi katmanı elemanını, j . gizli katman elemanına bağlayan bağlantının ağırlık değerini; y_k^i ise girdi katmanındaki k . işlemci elemanın çıktısını göstermektedir. j . gizli katman elemanının çıktısı ise bu net girdinin aktivasyon fonksiyonundan geçirilmesiyle hesaplanır. Aktivasyon fonksiyonu olarak genellikle sigmoid fonksiyon kullanılmakla birlikte, bu bir zorunluluk değildir, fakat geriye doğru hesaplamada fonksiyonun türevinin alınması gerektiğinden seçilen fonksiyonun, türevi alınabilir bir fonksiyon olmasına dikkat edilmelidir. Sigmoid fonksiyon kullanılması durumunda çıktı;

$$y_j^a = \frac{1}{1 + e^{-(s_j^a + \beta_j)}} \quad [3.7]$$

şeklindedir. Burada β_j , gizli katmanda bulunan j . elemana bağlanan eşik değer elemanın ağırlığıdır. Bu ağırlık değeri sigmoid fonksiyonun yönünü belirler. Eğitim esnasında ağırlık bu değeri kendisi belirler (Öztemel, 2003).

Ara ve çıktı katmanların işlemci elemanlarının çıktıları, aynı şekilde kendilerine gelen net girdinin (s_j^a) hesaplanması ve sigmoid fonksiyonundan geçirilmesi sonucu

belirlenmektedirler. Çıktı katmanından çıkan değerler, yani çıktılar, elde edilince ağırlık ileri hesaplama aşaması tamamlanmış olur.

Geriye doğru hesaplama aşamasında ise ağırlık sunulan girdi için ürettiği çıktı ile ağırlık beklenen çıktısı karşılaştırılmaktadır. Çıktı katmanındaki m . işlemci eleman için oluşan hata;

$$E = d_m - y_m \quad [3.8]$$

'dir. Bu bir tek işlemci eleman için oluşan hatadır. Çıktı katmanı için oluşan toplam hata ise;

$$E = \frac{1}{2} \sum_m E_m^2 \quad [3.9]$$

ile hesaplanır. Toplam hatayı en azlamak için işlemci elemanların hataları önceki katmanlara iletilir (geri yayılım). Hata önceki katmanlara iletilirken, aktivasyon fonksiyonunun türevi ile bir aktivasyon işlemi uygulanmaktadır. Hatanın iletilmesi, katman katman geriye doğru olmakta ve bu süreçte Delta kuralı kullanılarak bağlantı ağırlıkları ayarlanmaktadır. İşlem girdi katmanına ulaşılan kadar devam eder ve bu noktada yeni bir döngüye başlanır. Ağırlık ağırlıkları değiştirilirken iki durum söz konusudur. Bunlardan ilki, gizli katman ile çıktı katmanı arasındaki ağırlıkların değiştirilmesi; ikincisi ise gizli katmanlar arası veya gizli katman ile girdi katmanı arasındaki ağırlıkların değiştirilmesidir. Bu iki duruma göre hesaplama işlemi değişiklik gösterir.

Gizli katman ile çıktı katmanı arasındaki ağırlıkların değiştirilmesi şu şekilde açıklanabilir. Gizli katmandaki j . işlemci elemanı çıktı katmanındaki m . işlemci elemana bağlayan bağlantının ağırlığındaki değişim miktarı Δw_{jm}^a olmak üzere; herhangi bir t zamanında (t . iterasyonda) ağırlığın değişim miktarı,

$$\Delta w_{jm}^a(t) = \lambda \delta_m y_j^a + \alpha \Delta w_{jm}^a(t-1) \quad [3.10]$$

ile hesaplanır. Burada λ öğrenme oranını, α ise momentum katsayısını göstermektedir. Öğrenme oranı, ağırlıkların bir sonraki düzeltmede hangi oranda değiştirileceğini belirlemektedir. Ağ üzerinde önemli bir etkisi bulunan öğrenme oranının değeri, uygulanan probleme göre değişmekle birlikte küçük bir değer seçilmesi, öğrenme süresinin uzamasına, büyük bir değer seçilmesi ise ağıın yerel çözümlere takılmasına neden olur.

Yerel çözümün tanımı, şu şekilde açıklanabilir: Bir problemin çözümü için en az hatayı veren ağırlık vektörünü pratikte her zaman yakalamak mümkün olmayabilmektedir. Bu çözüm, ağıın sahip olabileceği en iyi çözümdür. Fakat bu çözüme nasıl ulaşılacağı tam olarak bilinmemektedir. Ağ eğitim sırasında bu çözüme ulaşmaya çalışır, ancak bazen ağ farklı bir çözüme takılabilmekte ve performansını daha fazla iyileştirmek mümkün olmamaktadır. Bu çözüm vektörlerine yerel çözümler denir. O nedenle tasarımcılar ağların ürettikleri çözümlerde ε (tolerans değeri) kadar hatayı kabul etmektedirler. Tolerans değerinin altındaki herhangi bir noktada problem öğrenilmiş kabul edilir (Öztemel, 2003).

Momentum katsayısı, ağın performansı üzerinde etkisi bulunan diğer bir parametredir. Özellikle yerel çözümlere takılan ağların bir sıçrama ile daha iyi sonuçlar bulmasını sağlamak amacıyla kullanılır. Bu değerın küçük olması yerel çözümlerden kurtulmayı, büyük olması ise tek bir çözüme ulaşmayı zorlaştırabilmektedir.

Eşitlikteki δ_m , m. işlemci elemanın hatasını göstermekte ve şu şekilde hesaplanmaktadır;

$$\delta_m = f'(s) \cdot E_m \quad [3.11]$$

Buradaki $f'(s)$ aktivasyon fonksiyonunun türevidir. Sigmoid fonksiyonu kullanılması durumunda;

$$\delta_m = y_m(1 - y_m) \cdot E_m \quad [3.12]$$

olacaktır. Değişim miktarı hesaplandıktan sonra ağırlıkların t . iterasyondaki yeni değerleri,

$$\Delta w_{jm}^a(t) = \Delta w_{jm}^a(t-1) + \alpha \Delta w_{jm}^a(t) \quad [3.13]$$

şeklini alır. Benzer şekilde eşik değer elemanının da ağırlıklarını değiştirmek gerekir. Onun için önce değişim miktarı hesaplanmalıdır. Eğer çıktı katmanındaki işlemci elemanların eşik değer ağırlıkları β^o ile gösterilirse, bu elemanın çıktısının sabit ve 1 olması nedeni ile değişim miktarı,

$$\Delta \beta_m^o(t) = \lambda \delta_m + \alpha \Delta \beta_m^o(t-1) \quad [3.14]$$

olacaktır. Eşik değer t . iterasyondaki ağırlığının yeni değeri ise,

$$\beta_m^o(t) = \beta_m^o(t-1) + \Delta \beta_m^o(t) \quad [3.15]$$

şeklinde hesaplanacaktır.

Geriye doğru hesaplama aşamasındaki ikinci durum gizli katmanlar arası veya gizli katman ile girdi katmanı arasındaki ağırlıkların değiştirilmesidir. Gizli katman ile çıktı katmanı arasındaki ağırlıkların değiştirilmesinde her ağırlık için sadece çıktı katmanındaki bir işlemci elemanın hatası dikkate alınırken, girdi katmanı ile gizli katman arasındaki (veya iki gizli katman arasındaki) ağırlıkların değiştirilmesinde çıktı katmanındaki bütün işlemci elemanların hatasından payını alması gerekmektedir. Bu ağırlıklardaki değişim (mesela girdi katmanı ile gizli katman arasındaki ağırlıkların değişimi) Δw ile gösterilirse değişim miktarı;

$$\Delta w_{kj}^i(t) = \lambda \delta_j^a y_k^i + \alpha \Delta w_{kj}^i(t-1) \quad [3.16]$$

olacaktır. Buradaki hata terimi δ_j^a şu şekilde hesaplanmaktadır.

$$\delta_j^a = f'(s) \sum_m \delta_m w_{jm}^a \quad [3.17]$$

Aktivasyon fonksiyonu olarak sigmoid fonksiyon kullanılması durumunda hata değeri,

$$\delta_j^a = y_j^a(1 - y_j^a) \sum_m \delta_m w_{jm}^a \quad [3.18]$$

ile hesaplanır.

Değişim miktarı hesaplandıktan sonra ağırlıkların t. iterasyondaki yeni değerleri ise,

$$w_{kj}^i(t) = w_{kj}^i(t-1) + \Delta w_{kj}^i(t) \quad [3.19]$$

kullanılarak hesaplanır.

Benzer şekilde gizli katman eşik değer ağırlıkları β^a ile gösterilirse değişim miktarı;

$$\Delta \beta_j^a(t) = \lambda \delta_j^a + \alpha \Delta \beta_j^a(t-1) \quad [3.20]$$

olacaktır. Ağırlıkların yeni değerleri ise t. iterasyonda şu şekilde hesaplanmaktadır.

$$\beta_j^a(t) = \beta_j^a(t-1) + \Delta \beta_j^a(t) \quad [3.21]$$

Böylelikle ağırlıklarının hepsi değiştirilmiş olur. Bir iterasyon hem ileri hem de geriye hesaplamaları yapılarak tamamlanır. İkinci bir örnek verilerek sonraki iterasyona başlanmakta ve aynı işlemler öğrenme tamamlanıncaya kadar yinelenmektedir.

3.8.1. ÇKA modellemede önemli noktalar

Başarılı bir tahmin gerçekleştirebilmek için kurulacak olan ÇKA modeli oldukça öneme sahiptir. Ancak modellemeye başlamadan önce dikkat edilmesi gereken en önemli unsur probleme ilişkin toplanan verilerdir.

Zaman serisi analizine dayalı tahmin problemlerinde veri ilgili değişkenin serisidir. Kurulan ÇKA'da girdi ve çıktı nöron değerlerini oluşturacak olan veri de bu seriye ait sıralı gözlem değerleridir. Sebep-sonuç ilişkisine dayalı tahmin problemlerinde ise; çıktı nöronu değerleri bağımlı değişkene ait veriler iken girdi nöronu değerleri bağımsız değişkenlere ait verilerdir. Böyle bir tahmin problemde bağımsız değişkenlerin seçiminde özen gösterilmeli ve modeli şişirecek çok fazla sayıda değişken kullanımından kaçınılmalıdır. Ayrıca bağımsız değişkenler arasında mevcut olabilecek çoklu doğrusal bağlantı ya da birlikte değişim gibi durumların varlığı araştırılmalı, eğer varsa bu durum giderilmeye çalışılmalıdır [Hamzaçebi, 2011].

Probleme ilişkin yeterli ve sağlıklı veriler toplandıktan sonra ÇKA modellemesine geçilebilir. ÇKA modellemesinde en önemli kararlardan biri ağ yapısıdır. Ağ yapısından kasıt, katman sayısı, her katmandaki nöron sayısıdır. Diğer kritik kararlar ise, gizli katman ve çıktı katmanındaki aktivasyon fonksiyonunun seçimi, eğitim algoritması, veri normalleştirme metodu, veri kümesinin belirlenmesi ve performans ölçütleridir.

Ağ yapısı

ÇKA'nın tasarımında girdi nöronu sayısı, gizli katman sayısı, gizli nöron sayısı ve çıktı nöronu sayısının belirlenmesi gerekmektedir. Bu parametrelerin seçimi ilgilenilen probleme göre değişecektir. Optimal ağ mimarisinin belirlenmesinde, önerilen bazı teknikler olmasına rağmen, bu metotlardan hiçbirisi gerçek tahmin problemleri için optimal çözümü garanti etmemektedir. Daha doğrusu bu parametrelerin belirlenmesinde kesin-açık metotlar yoktur. Sezgisel yaklaşımlar ve kısıtlı deneylere dayalı benzetim çalışmaları yardımcı olabilir. Bu nedenle, bir YSA'nın tasarımı bir bilimden daha çok bir sanattır. Ancak model seçimini kolaylaştıracak bazı yaklaşımlar vardır. Örneğin model karmaşıklığını engelleme amaçlı BIC (Bayesian Information Criterion) istatistiği model belirlemede kullanılabilir. BIC hesaplaması Eş. 3.22'da gösterilmiştir [Hamzaçebi, 2011].

$$BIC = N \ln\left(\frac{HKT}{N}\right) + P \ln(N) \quad [3.22]$$

Eş. 3.22’de; N, eğitim kümesi örnek büyüklüğünü, HKT, hata kareleri toplamını, P, ağ parametre sayısını göstermektedir. Ağ parametre sayısı, kurulan ağda mevcut bağlantı sayısına eşittir.

Girdi nöronu sayısı

Sebe-sonuç ilişkisine dayanan bir tahmin problemi ilişkin bağımsız değişken sayısı girdi nöronu sayısını verecektir. Girdi nöronları veri içerisinde saklı bilgiyi ortaya çıkarmada çok önemli bir rol oynarlar, bu sebeple de en uygun girdi nöronu sayısının tespiti oldukça önemlidir.

Gizli katman sayısı

Tek gizli katmanlı ÇKA problemleri çözmede başarılıdır. Ancak bazen çok karmaşık bir yapıyı barındıran verilerle çalışırken iki gizli katmana ihtiyaç duyulabilir. Gizli katman sayısının artırılması, hesaplama zamanını artırmakta ayrıca ağın öğrenme yerine ezberlemesine sebep olabilmektedir. Ağ ağırlıklarının sayısı, gizli katman ve nöron sayısına bağlı olarak değiştiği için eğitim kümesinin büyüklüğü ezberleme işleminin ortaya çıkıp çıkmayacağını belirler. Eğitim kümesine göre çok sayıdaki ağırlık değeri, ağın özel gözlem değerlerini ezberlemesine sebep olacaktır.

Gizli nöron sayısı

Gizli katmanlardaki nöron sayısının tespitinde sabit bir kural yoktur. Genel olarak şunu söylemek gerekir: az sayıda gizli nöron veri yapısındaki ilişkiyi öğrenmede başarısız olabilir, çok sayıda gizli nöron ise ağın öğrenmesi yerine ezberlemesine sebep olur. En uygun gizli nöron sayısını belirlemek için, deney tasarımı yapılabilir, ya da az sayıda gizli nöron ile başlayıp doğrulama kümesi için ağın performansı bozuluncaya kadar gizli nöron sayısı artırılır. Literatürde, yapılan deneysel

alışmaların sonucunda, “n” girdi nöronu ve “m” çıktı nöronu sayısını göstermek üzere, tek gizli katmanlı ağlarda gizli nöron sayısına ilişkin bazı öneriler şunlardır [Hamzaebi, 2011]:

- a) n
- b) $2n + 1$
- c) $2n$
- d) $\sqrt{n * m}$
- e) $0.75 * n$

Çıktı nöronu sayısı

Çıktı nöronu sayısını hesaplamak kolaydır ve alışılan probleme direkt baėlıdır. Sebep-sonuç ilişkisine dayalı tahmin problemlerinde çıktı nöronu sayısı baėımlı deėişken sayısına eşit alınabilir. Zaman serisi analizine dayalı tahmin probleminde çıktı nöronu sayısı, tahmin döneminin uzunluėuna eşittir.

Aktivasyon fonksiyonu

Tahmin problemleri için kurulan KA’larda, aktivasyon fonksiyonu aėın performansını etkileyen bir başka önemli faktördür. Aktivasyon fonksiyonunun seçimi aėın performansını etkilemesine raėmen hangi fonksiyonun kullanılacaėını belirleyen kesin bir kural yoktur. Genel olarak, bir aėın, aynı ya da farklı katmanlarındaki nöronlar farklı aktivasyon fonksiyonunu kullanabilirler. Ancak uygulamaların çoėunda, aynı katmandaki nöronların aynı aktivasyon fonksiyonunu kullandıkları görölmektedir.

Literatürdeki alışmaların çoėunda gizli katman nöronları için sigmoid (lojistik) ya da hiperbolik tanjant aktivasyon fonksiyonu kullanılırken, çıktı nöronları için hangi aktivasyon fonksiyonunun kullanılması gerektiėi hususunda bir görüş birliėi yoktur. Çıktı katman nöronları için sigmoid, hiperbolik tanjant ya da özdeşlik fonksiyonunun kullanıldığı görölmektedir [Hamzaebi, 2011].

Veri Normalleştirme

Lojistik ya da hiperbolik tanjant gibi doğrusal olmayan aktivasyon fonksiyonları, bir nöronun çıktısını (0,1) veya (-1,1) aralığına sıkıştırırlar. Bu sebeple hesaplama hatalarından kaçınmak için hem çıktıları hem de girdileri normalleştirme avantajlı olacaktır. Veri normalleştirme (data normalization), eğitime süreci başlamadan uygulanır. Veri normalleştirme yaklaşımlarında, sıklıkla aşağıdaki formüller kullanılmaktadır [Zhang ve ark., 1998]:

a) [0,1] aralığına doğrusal dönüşüm:

$$x_n = \frac{x_0 - x_{\min}}{x_{\max} - x_{\min}} \quad [3.23]$$

b) [a,b] aralığına doğrusal dönüşüm:

$$x_n = (b - a) \frac{x_0 - x_{\min}}{x_{\max} - x_{\min}} + a \quad [3.24]$$

c) Basit normalizasyon:

$$x_n = \frac{x_0}{x_{\max}} \quad [3.25]$$

d) İstatistiksel normalizasyon:

$$x_n = \frac{x_0 - \bar{x}}{s} \quad [3.26]$$

x_n ve x_0 , normalleştirilmiş ve orijinal veriyi temsil etmektedir. $x_{\min}$, $x_{\max}$, $\bar{x}$ ve s , sırasıyla minimum, maksimum, ortalama ve standart sapmayı ifade etmektedir.

Öğrenme algoritması

Ağ eğitimi için birçok değişik optimizasyon metodu vardır. En yaygın kullanılan öğrenme (eğitim) algoritması, esasında bir gradyan dik iniş algoritmasıdır. Gradyan dik iniş algoritması için öğrenme oranı ve momentum katsayısının en iyi değerlerinin belirlenmesi oldukça önemlidir. Bu öğrenme parametrelerinin en iyi değerleri genellikle deney yolu ile belirlenir. Öğrenme oranı ve momentum katsayısı, her ikisi de genellikle 0 ile 1 arasında herhangi bir değer alabilir.

Veri kümesinin düzenlenmesi

ÇKA'nın tahmin performansını etkileyen bir diğer faktör de veri kümesinin büyüklüğüdür. Herhangi bir istatistiksel yaklaşımdaki gibi, veri kümesi büyüklüğü, çözümün doğruluğu ile yakından ilgilidir. Verilen bir problemin ÇKA ile çözümü için ne kadar büyüklükte bir örnek gerektiği; ağın yapısına ve veri içerisindeki karmaşıklığa bağlıdır. Yeterli sayıda veri kullanıldığında ÇKA, verideki herhangi bir karmaşık yapıyı modelleyebilir [Zhang ve ark., 1998].

Bir ÇKA ile tahminde bulunurken eldeki mevcut veri kümesi eğitim-test ya da eğitim-doğrulama-test olmak üzere kısımlara ayrılır. Eğitim kümesi verileri, kurulan ÇKA'nın öğrenmesi, doğrulama kümesi verileri eğitim sürecinin durdurulacağı zamanın belirlenmesi ve test kümesi verileri de ÇKA sonuçlarının genelleştirilebilmesi için kullanılır. Doğrulama kümesi verileri aynı zamanda farklı ağ yapılarının seçiminde de kullanılabilir.

Eldeki verilerin anılan kümelerle bölünmesinde dikkat edilecek bazı kriterler vardır. Problem karakteristiği, veri tipi ve eldeki veri miktarı bu kararı vermede dikkate alınır. Her üç kümeye ait verilerin, bütünün özelliklerine sahip kümeler olması kritik bir noktadır. Bu nokta özellikle zaman serileri tahmin problemlerinde önemlidir. Eğitim-doğrulama-test kümelerinin uygunsuz belirlenmesi, ÇKA'nın tahmin performansını ve bu performansın değerlendirilmesini etkileyecektir. Literatürde eğitim, doğrulama ve test kümelerinin belirlenmesine yönelik az da olsa öneriler

vardır. Birçok araştırmacı %80,%10,%10 veya %70,%15,%15 ya da %60,%20,%20 kuralını temel alan bir yöntem izlemiştir. Bu oranların eldeki veri sayısı ile de yakından alakalı olduğu unutulmamalıdır [Zhang ve ark., 1998].

ÇKA'nın Performansının Belirlenmesi

Herhangi bir problemi çözme için geliştirilen bir modelin performansından söz edildiğinde akla ilk olarak modelin ne kadar hızlı çalıştığı ya da ne kadar doğru çalıştığı gelir. Hızlı sonuç üretme şüphesiz önemli bir performans göstergesidir. Ancak ondan daha önemlisi modelin doğru sonuç üretmesidir. Bu kısımda tahmin amaçlı kurulan bir ÇKA'nın en önemli performans ölçütü olan tahminin doğruluğu konusuna değinilecektir. Tahminin doğruluğu tahmin hatalarının analiz edilmesi ile belirlenir. Tahmin hatası, gerçek gözlem değeri ile tahmin edilen değer arasındaki farktır. Tahmin hatası,

$$e = Y - F \quad [3.27]$$

eşitliği ile hesaplanır. Y , gerçek gözlem değerini ve F de modelin ürettiği değeri ifade etmektedir. İncelenilen bir süreç ve tahmin metodu için tahmin hatasının, ortalaması $E(e)$ ve varyansı σ_e^2 olan normal tesadüfi bir değişken olduğu varsayılır. Eğer tahmin yanlı değilse, $E(e) = 0$ olur. Yanlı olmayan bir tahmin arzu ediliyorsa, geniş miktarda gözlem değeri ile çalışılması oldukça önemlidir. Tahmin doğruluğunu ölçmek üzere birçok doğruluk ölçütü tanımlanmıştır ve her birinin kendine göre avantajları ve dezavantajları vardır. Sıklıkla kullanılan performans ölçütleri aşağıdaki eşitliklerde gösterilmiştir [Hamzaçebi, 2011]:

$$\text{Ortalama Hata (OH)} = \frac{1}{n} \sum_{i=1}^n e_i \quad [3.28]$$

$$\text{Ortalama Mutlak Hata (OMH)} = \frac{1}{n} \sum_{i=1}^n |e_i| \quad [3.29]$$

$$\text{Hata Kareleri Toplamı (HKT)} = \sum_{i=1}^n e_i^2 \quad [3.30]$$

$$\text{Hata Kareleri Ortalaması (HKO)} = \frac{1}{n} \sum_{i=1}^n e_i^2 \quad [3.31]$$

$$\text{Ortalama Mutlak Yüzde Hata (OMYH)} = \frac{1}{n} \sum_{t=1}^n \left| \frac{e_t}{Y_t} \right| * 100 \quad [3.32]$$

Her bir ölçütün kendine göre kısıtlamaları olduğundan dolayı, herhangi bir problem için birden fazla performans ölçütü kullanılabilir. Benzer bir ölçüt ÇKA'nın eğitimi aşamasında da kullanılmaktadır. Bu ölçüt tipik olarak HKT ya da HKO'dur.

4. YSA ile Türkiye Net Enerji Talep Tahmini

Türkiye'nin net enerji talebinin YSA ile tahmini için yapılan tez çalışmasının uygulama bölümü; veri, YSA uygulaması, bulgular, karşılaştırma ve tahmin kısımlarından oluşmaktadır.

4.1. Veri

Literatürde sebep-sonuç ilişkisine dayanan tahmin yöntemlerinde ve YSA ile yapılan çalışmalarda kullanılan bağımsız değişkenlerin farklılık gösterdiği görülmektedir. GSYH, nüfus, ithalat ve ihracat gibi değişkenler birçok çalışmada kullanılan ortak değişkenlerdir. Gerçekleştirilecek uygulama kapsamında ise anılan değişkenlerle birlikte bina yüzölçümü ve taşıt sayısı değişkenleri de bağımsız değişken olarak kullanılacaktır. YSA ile kurulan model ile net enerji talep tahmini doğru daha bir şekilde tahmin edebilmek için modele eklenebilecek bağımsız değişkenler araştırılmış ve YSA için yeterli sayıdaki geçmiş gözlem değerlerine ulaşılan bina yüzölçümü ve taşıt sayısı değişkenleri bağımlı değişken olarak modele eklenmiştir. Çizelge 4.1'de kullanılan bağımsız değişkenlere ilişkin bilgiler sunulmaktadır.

Çizelge 4.1. Çalışmada kullanılan değişkenler


Değişken Sembolü	Değişken Adı	Kaynağı	Değişken kullanılma sebebi
X_1	GSYH	Kalkınma Bakanlığı	Veriler Tük tarafından açıklanan büyüme hızları dikkate alınarak uyumlaştırılmış, yani aynı hesaplama yöntemiyle elde edilmiştir. GSYH büyüme göstergesi olması sebebiyle, büyümeye paralel olarak enerji talebinin de etkileneceği düşünülmüş ve GSYH bağımsız değişken olarak kullanılmıştır.
X_2	Nüfus	Kalkınma Bakanlığı	Nüfus oranlarında meydana gelen değişimle birlikte enerji tüketim miktarının değişmesi beklenmektedir. Bu nedenle yıl ortası nüfus verileri bağımsız değişken olarak kullanılmıştır.
X_3	İthalat	TÜİK	İthalat verileri bir ülkenin ticaret akışını, dolayısıyla enerji tüketimini etkilemektedir.
X_4	İhracat	TÜİK	İhracat verileri, ülkede gerçekleşen ticaret hacminin, üretimin dolayısıyla enerji tüketiminin bir göstergesidir.
X_5	Bina yüzölçümü	TÜİK	Bina yüz ölçümündeki değişimler şehirleşmenin bir göstergesidir. Bina yapımı sadece bir kalemi değil birçok kalemi etkileyebilmesi ve de ülkedeki pozitif hareketliliğe işaret olması nedeniyle çalışmaya bağımsız değişken olarak eklenmiştir. Ayrıca doğalgaz, kömür, elektrik vb. enerji kaynaklarının tüketimine etki etmektedir.
X_6	Taşıt sayısı	TÜİK	Taşıt sayısını, petrol ve doğalgaz tüketimiyle ilişkilendirmek mümkündür. Bu nedenle bağımsız değişken olarak çalışmaya ilave edilmiştir.
Y	Net enerji talebi	ETKB	Bağımlı değişkeni ifade eden bağımsız değişkenler kullanılarak net enerji talebi hesaplanacaktır.

1970’den 2010 yılına kadar resmi kaynaklardan elde edilen bağımsız ve bağımlı değişkenler için veriler toplandıktan sonra MATLAB yazılımında “.m” dosyası oluşturularak YSA model kurulumu gerçekleştirilmiştir.

4.2. YSA Uygulaması

4.2.1. Ağ yapısı

Bağımsız değişkenlerin girdi, net enerji tüketiminin çıktı değişkeni olarak kullanıldığı YSA yapısı Şekil 4.1’de gösterilmektedir.



Şekil 4.1. Türkiye net enerji talebi için YSA yapısı

4.2.2. Veri düzenleme ve dönüştürme

Eldeki verilerin %70’i eğitim, %15’u doğrulama ve %15’u test seti için kullanılmıştır. Bu yüzdeler için literatürde kullanılan değerler dikkate alınmış ve deneme-yanılma yolu ile model performansını artıran veri düzenlemeleri gerçekleştirilmiştir [Zhang ve ark., 1998]. Hem girdi hem çıktı verileri [0,1] aralığına dönüştürülmüştür.

4.2.3. Ağ optimizasyonu

Problemin yapısından anlaşılabacağı üzere girdi nöronu sayısı bağımsız değişken sayısına eşit olup 6’dır. Çıktı nöronu sayısı da bağımlı değişkene eşit olup 1’dir. Girdi ve çıktı nöronları kullanılarak ileri beslemeli geri yayılım yapay sinir ağı


kurulmuştur. Literatürdeki çalışmalarda tek gizli katman sayısı başarılı sonuçlar elde etmede yeterli olduğundan tek gizli katman tercih edilmiştir. Gizli katmandaki nöron sayısı ise literatürdeki deneysel yaklaşımlardan hareketle kullanılacak tekniklerden eğitim ve doğrulama için en iyi sonucu veren gizli nöron sayısı bulunmaya çalışılmıştır. Kurulan yapay sinir ağları modelinde gizli katman aktivasyon fonksiyonu olarak sigmoid aktivasyon fonksiyonu kullanılmıştır.

Çıktı katmanı aktivasyon fonksiyonu olarak ise doğrusal aktivasyon fonksiyonu tercih edilmiştir. Bu tercihler yapılırken performans değerlendirmesinin sonuçları göz önüne alınmıştır. Öğrenme metodu için en iyi sonucu veren yöntem araştırılmış ve Bayesyen düzeltmeye dayalı geri yayılım algoritması kullanılmıştır.

Çalışmada HKT ve OMYH performans ölçütleri kullanılmıştır. Ağın eğitimi sırasında hata performans fonksiyonu olarak HKT ve kurulan modelin başarısını karşılaştırma amacı ile de OMYH performans ölçütü kullanılmıştır.

4.2.4. Bulgular

Model 2000 döngü için eğitilmiş ve bu eğitime ilişkin HKT (sum squared error) fonksiyonunun grafiği Şekil 4.2’de görülmektedir. Model en iyi performansı 304. döngüde yakalamıştır.



Şekil 4.2. Eğitim kümesi HKT grafiği

Model eğitiminin başarısı görebilmek için bir de OMYH değerleri modele hesaplattırılmıştır. Eğitimin OMYH değerinin düşük olması her zaman doğru sonuç verdiğini göstermez. Çünkü ağıın eğitiminde öğrenme yerine ezberleme noktasına gelinmiş olabilir. Bu durumdan kaçınmak için doğrulama kümesi kullanılmakta ve en iyi performansı veren modelin seçiminde, eğitim sonunda elde edilen doğrulama kümesi OMYH değerleri de göz önüne alınmaktadır. Eğitim ve doğrulama kümesi değerleri Çizelge 4.2’de yer almaktadır.

Çizelge 4.2. YSA modeli OMYH değeri

	YILLAR	OMYH (%)
Eğitim kümesi	1970-1995	1,70
Doğrulama kümesi	1996-2003	4,92

Eğitim kümesi için elde edilen %1,7’lik hata değeri eğitimin oldukça başarılı bir şekilde gerçekleştiğini bize kanıtlamaktadır. Çünkü eğitim kümesi için kurulan modelin elde ettiği değerler ile gerçek değerler arasında %1,70’lik bir hata payı bulunmaktadır. Ayrıca doğrulama kümesi için %4,92’lik değerde ağıın doğru bir şekilde eğitildiğini, ezberleme yapmadığını göstermektedir.


Ağıın eğitiminin tamamlanması ağıın ağırlıklarının belirlenmesi anlamına gelmektedir. Belirlenen bu ağırlıklar bilinmemektedir. Bu nedenle YSA kapalı kutu olarak nitelendirilmektedir. Modelin eğitimi sonucu elde edilen ağırlıkların ne derece doğru tahmin yaptığını görebilmek için YSA modelinin sınanması gerekmektedir. Çizelge 4.3’de modelin tahmin ettiği test kümesinin tahmin değerleri, gerçek değerlerle karşılaştırılmış, MYH ve OMYH değerleri hesaplanmıştır.

Test kümesinde elde edilen %1,75’lik OMYH değeri modelin başarılı tahminler gerçekleştirebilecek düzeyde olduğunu göstermektedir. Çünkü kurulan modelde test kümesi için elde edilen tahmin değerleri ile gerçek değerler arasındaki hata payı oldukça düşüktür. Bu da başarılı tahminlerin yapılabileceğini kanıtlamaktadır.

Çizelge 4.3. Test kümesi OMYH değeri

YILLAR	GERÇEK (B.TEP)	YSA MODELİ (B.TEP)	MYH (%)
2004	87818	85026	3,18
2005	91362	93373	2,20
2006	99590	99599	0,01
2007	107625	105309	2,15
2008	106273	108952	2,52
2009	106138	105306	0,78
2010	109266	110799	1,40
		OMYH	1,75

Ağın eğitilmesinden sonra elde edilen ağırlık değerleri; eğitim, doğrulama ve test kümelerinin tahmini için kullanılmış ve elde edilen sonuçlar gerçek değerlerle karşılaştırmalı olarak Şekil 4.3'te sunulmuştur.



Şekil 4.3. Gerçek değerler ve tahmin değerleri

Şekil 4.3'teki grafikte modelin eğitim, doğrulama ve test kümesi için elde ettiği tahmin değerleri gerçek değerlere yakın ve oldukça başarılıdır.

Kurulan YSA modelinin başarısı OMYH performans ölçütü ile sınanmış ve başarılı tahminler ortaya koyabileceği saptanmıştır. Modelin güvenilirliğini artırmak amacıyla bir sonraki bölümde çoklu regresyon ve zaman serileri yöntemleriyle uygun modeller kurulacak ve sonuçlar YSA modeli ile karşılaştırılacaktır.

4.3. Karşılaştırma

OMYH değeri yapılan çalışmanın başarısını ölçmede oldukça belirleyici olmasına rağmen sebep-sonuç ilişkisine ve zaman serisine dayanan tahmin teknikleri kullanılarak da kurulan modelin test edilmesi çalışmanın güvenilirliğini artırmaktadır. Bu nedenle çalışmada sebep-sonuç ilişkisine dayalı tahmin yöntemlerinden çoklu regresyon modeli ve zaman serisine dayalı tahmin yöntemleri arasında yer alan YSA’nda zaman serisi modeli geliştirilerek karşılaştırmalar yapılacaktır.

4.3.1. Çoklu doğrusal regresyon modeli

Regresyon modelinde, etkileyen değişkenlere açıklayıcı değişken (bağımsız değişken), etkilenen değişkene de açıklanan (bağımlı değişken) adı verilir. Y bağımlı değişken; $X_1, X_2, \dots, X_n$ bağımsız değişkenler olmak üzere değişkenler arasındaki sebep-sonuç ilişkisini matematiksel bir model olarak ortaya koyan yönteme çoklu doğrusal regresyon modeli adı verilir.

Çoklu doğrusal regresyon modeli,

$$Y = b_0 + b_1X_1 + b_2X_2 + \dots + b_nX_n \quad [4.1]$$

biçiminde ele alınan bir doğrusal modelde parametre tahmini yapmayı amaçlar. Regresyon modelleri doğrusal ya da doğrusal olmayan modeller olarak sınıflandırılabilir. Ancak doğrusal olmayan modeller çeşitli yöntemlerle doğrusal modellere dönüştürülebilir.

YSA modelinde kullanılan girdi değişkenleri çoklu doğrusal regresyon modelinde bağımsız değişkenler olarak, YSA modelinde kullanılan çıktı değişkeni ise çoklu doğrusal regresyon modelinde bağımlı değişken olarak kullanılmıştır. YSA modelindeki eğitim kümesi bağımsız değişken verileri MİNİTAB programında analiz edilerek çoklu doğrusal regresyon modeli kurulmuştur. Ancak kurulan regresyon modelinin, istatistiksel anlamlılığa sahip olmadığı ve gerekli varsayımları sağlamadığı görülmüştür. Bu nedenle söz konusu değişkenlerle elde edilen çoklu regresyon modelinin istatistiksel varsayımlarını sağlamadığı için modele düzeltici yöntemler uygulanmıştır.


YSA sınırsız sayıda bağımsız değişken kullanarak analiz yapabilmesine karşın, regresyon yöntemi çoklu doğrusal bağlantı probleminin oluşmaması için, sınırlı sayıda ve ilişkisiz bağımsız değişken kullanabilmektedir. Öncelikle YSA modelinde kullanılan değişkenlerle istatistiksel olarak anlamlı regresyon modeli kurulamadığından modelin müsaade ettiği bağımsız değişkenler belirlenmiş izlenmiş ve GSYH, ithalat ve ihracat bağımsız değişkenleri modelden çıkarılmıştır. sonra modele tam kare transformasyonu uygulanmış ve çoklu doğrusal bağlantı problemi artadan kaldırılarak model uygun hale getirilmiştir. 1970-1995 yılları arasındaki nüfus, bina yüz ölçümü ve taşıt sayısı bağımsız değişken verileri MİNİTAB programında analiz edilmiş ve aşağıdaki sonuçlar elde edilmiştir.

Çizelge 4.4. MİNİTAB analiz sonuçları

Tahmin değişkeni	Katsayı	Standart Hata Katsayısı	T	P	VIF
Sabit	-51,55	12,76	-4,04	0,001	
Nüfus	0,69332	0,07606	9,12	0,000	6,971
Bina yüz ölçümü	0,6896	0,1266	5,45	0,000	9,652
Taşıt sayısı	0,39126	0,07318	5,35	0,000	6,061
S = 10,5121	R-kare = 99,2%		R-kare(düzeltilmiş) = 99,1%		
Varyans Analizi					
Kaynak	DF	SS	MS	F	P
Regresyon	3	303581	101194	915,74	0,000
Durbin-Watson istatistiği = 1,62					


Modelin bağımsız değişkenlerinin her biri için $p < 0.05$ olduğundan istatistiksel olarak anlamlı ve önemli sonucuna ulaşılır. Modelin açıklayıcılığı %99,2 olarak elde

edilmiştir. F testi sonucunda, $p < 0.05$ olduğundan istatistiksel olarak anlamlılık düzeyindedir. Modeldeki bağımsız değişkenler arasında çoklu doğrusal bağlantının(multycollinearity) olup olmadığını test etmek için varyans artış faktörü(VIF) değerleri dikkate alınmıştır. VIF değerleri 10'dan küçük olduğundan bağımsız değişkenler arasında çoklu bağlantı yani bağımlılık yoktur. Daha sonra tahmin hataları arasında bağımlılık olup olmadığı araştırılmıştır. Bu nedenle Durbin-Watson istatistiği kullanılmıştır.



Şekil 4.4. Durbin-Watson testi kararlarının şematik gösterimi

26 gözlem sayısı için Durbin-Watson d istatistiği kritik değerleri $d_L = 1,14$ ve $d_U = 1,65$ 'tir. Modelden elde edilen d değeri 1,62'dir. Bu değer Şekil 4.4'de görüldüğü üzere kararsızlık kısmına düşmekte ancak H_1 kabul aralığına oldukça yakındır. Modelin hata paylarına ilişkin grafiği de Şekil 4.5'te görüldüğü gibidir.



Şekil 4.5. Çoklu doğrusal regresyon modelinin hata payları grafiği

Gerçekleşen ve tahmin edilen net enerji talep değerlerinin birbirine örtüşen yapıda olduğu ve aralarındaki sapmaların aşırılık göstermediği görülmektedir. Elde edilen

bu modeli tahmine uygun olarak nitelemek yanlış olmayacaktır. Ancak elde edilen regresyon modelinde net enerji talebinin tahmin etmek için nüfus, bina yüz ölçümü ve taşıt sayısı değişkenleri kullanılmıştır. Daha gerçekçi bir karşılaştırma yapabilmek için regresyon modelinde kullanılan aynı değişkenlerle tekrar bir yapay sinir ağı (kYSA) modeli kurulmuş ve aynı yıllar baz alınmıştır. Çoklu doğrusal regresyon modelinin(ÇDRM) ve kYSA modelinin analiz sonuçları Çizelge 4.5'te verilmiştir.

Çizelge 4.5. ÇDRM ve kYSA tahmin değerleri ve OMYH

YILLAR	GERÇEK	TAHMİN		MYH (%)	
		ÇDRM	kYSA	ÇDRM	kYSA
2004	87818	76455	87748	12,94	0,08
2005	91362	87093	93805	4,67	2,67
2006	99590	94552	93318	5,06	6,30
2007	107625	100771	94248	6,37	12,43
2008	106273	103419	104878	2,69	1,31
2009	106138	118065	112684	11,24	6,17
2010	109266	115098	109860	5,34	0,54
			OMYH	6,89	4,21


Çizelge 4.5'te görüldüğü üzere kYSA modeli OMYH değeri ÇDRM göre daha düşüktür. kYSA modelinde kullanılan değişkenler regresyon modelinin izin verdiği değişkenlerden seçilmiş olmasına rağmen daha başarılı sonuçlar verdiği görülmüştür. Buradan hareketle çalışma başlangıcındaki YSA modelinde, kYSA'da kullanılan (nüfus, bina yüz ölçümü ve taşıt sayısı) bağımsız değişkenlere ek olarak GSYH, ithalat ve ihracat değişkenleri de kullanılmıştı. Bu değişkenlerin eklenmesiyle YSA modelinin kYSA modeline oranla daha başarılı sonuçlar verdiği de görülmüştür. Bu noktadan hareketle YSA modelinde kullanılan bağımsız değişkenlerin etkin sonuç elde etmede katkısı olduğu saptanmış ve doğrulanmıştır.

4.3.2. YSA zaman serisi modeli

Zaman serisi analizine dayalı tahmin problemleri, bir değişkenin zaman boyutunda mevcut verileri ile gelecek dönemlere ait değerlerin tahmin edilmesi olarak bilinir. Zaman serisi analizine dayalı tahmin probleminde, girdiler veri serisinin geçmiş gözlemlerinden oluşurken, çıktı gelecekteki tahmin değeridir [Hamzaçebi, 2011].

Box-Jenkins modelleri, doğrusal bir yöntem olan ve en yaygın olarak kullanılan zaman serisi tahmin tekniğidir. 1980'li yılların ikinci yarısından itibaren zaman serisi tahmini amacı ile de kullanılan ÇKA'lar, özellikle doğrusal olmayan bir ilişkiyi içeren zaman serilerinin tahmininde başarılı olmuştur.

Zaman serileri tahmininde ÇKA'nın girdisi ve çıktısı seriye ait gözlem değerleridir. Girdi nöronu sayısı, seri değerinin kaç adet geçmiş gözlem değeri ile ilişkilendirileceğine göre değişir. Girdi nöronu sayısının 2 olması, serinin t zamanındaki değerinin $t-1$ ve $t-2$ zamanı gözlem değerlerine bağlı olduğu anlamına gelir. Çıktı nöronu sayısı ise tek dönemlik tahmin için 1'e eşittir. Bu bilgiler dikkate alınarak girdi veri kümesi ve çıktı veri kümesi düzenlenir. Çalışmada girdi nöronu sayıları için denemeler yapılmış ve net enerji talebinin tahmininde en uygun modelin 3 girdi nöronlu olduğu tespit edilmiştir. ÇKA ile zaman seri modeli Şekil 4.6'da görülmektedir.



Şekil 4.6. Zaman serisi tahmini için kurulan ÇKA

ÇKA ile zaman seri modeli(ZS) MATLAB'da ".m" dosyası oluşturularak kodlanmış ve YSA modelinde kullanılan veriler eğitim, doğrulama ve test kümelerine bölüştürülerek karşılaştırmalar yapılmıştır. Analiz sonuçları çizelge 4.6'da özetlenmektedir.

Çizelge 4.6. ZS ve YSA tahmin değerleri ve OMYH

YILLAR	GERÇEK	TAHMİN		MYH (%)	
		ZS	YSA	ZS	YSA
2004	87818	86013	85026	2,06	3,18
2005	91362	90523	93373	0,92	2,20
2006	99590	94211	99599	5,40	0,01
2007	107625	101544	105309	5,65	2,15
2008	106273	109932	108952	3,44	2,52
2009	106138	110691	105306	4,29	0,78
2010	109266	110006	110799	0,68	1,40
			OMYH	3,21	1,75

Çizelge 4.6’da görüldüğü üzere YSA modeli ZS modeline göre daha başarılı sonuç vermektedir.

Yapılan karşılaştırmalar ve analizler sonucunda kurulan YSA modelinin hem ÇDRM hem de ZS modeline üstünlük sağladığı ve oldukça başarılı tahminler gerçekleştirdiği görülmüştür. Bir sonraki bölümde YSA modeli ile tahminler gerçekleştirilecektir.

4.3.3. Tahmin

Gelecekteki net enerji talebini tahmin edebilmek için YSA modelinde kullanılan bağımsız değişkenlerin gelecekteki değerlerinin bilinmesi gerekmektedir. Bu nedenle ilerleyen süreçte gerçekleştirilecek senaryolar türetilerek bu değerler elde edilmiş ve tahmin çalışması gerçekleştirilmiştir.

Mevcut gözlem değerleri arasından rastgele seçilen veri sayısı $n \geq 30$ olduğunda normal dağılım gösterdiği varsayılır. Bağımsız değişken olarak kullanılan 41 tane yıllara göre yüzde değişim gözlem değerlerinden 32 tanesi seçilip ortalamaları ve %95 güven aralığındaki en küçük ve en yüksek değerleri belirlenmiştir. Bu değerler için ortalamanın %95 güven aralığındaki en düşük değeri düşük senaryo, en yüksek değeri yüksek senaryo ve ortalama değeri ise beklenen senaryo olarak adlandırılmış

ve bu deęerler izelge 4.7’de verilmiřtir. Nfus verileri iin TİK’nun yıl ortası nfus tahmin deęerleri kullanılmıřtır.


izelge 4.7. Senaryolar ve yzdelik deęerleri

	GSYH	İthalat	İhracat	Bina Yzlm	Tařıt sayısı
Dřk Senaryo	3,70%	9,10%	9,30%	1,20%	6,90%
Beklenen Senaryo	4,80%	15,80%	15,20%	6,10%	8,60%
Yksek Senaryo	5,90%	22,50%	21,10%	11,10%	10,30%

alıřmada kurulan YSA modeline bu senaryolar uygulanarak 2011-2025 yılları arasındaki net enerji talebi tahmin edilmiřtir. Bu tahmin deęerleri izelge 4.8 verilmiřtir. Senaryolara gre tahmin grafięi řekil 4.7’de grlmektedir.

izelge 4.8. Senaryolara gre YSA tahmin deęerleri

Yıllar	Dřk Senaryo	Beklenen Senaryo	Yksek Senaryo
2011	113934	115791	117312
2012	117258	120919	124210
2013	120636	126169	131315
2014	124061	131517	138567
2015	127529	136943	145896
2016	131032	142419	153225
2017	134563	147917	160480
2018	138115	153409	167602
2019	141679	158870	174554
2020	145248	164281	181330
2021	148813	169631	187939
2022	152366	174918	194391
2023	155899	180158	200649
2024	159404	185375	206597
2025	162875	190609	212024



Şekil 4.7. Senaryolara göre YSA tahmin grafiği

5. SONUÇ

Bu çalışmada, nicel tahmin metotlarından YSA modeli ile sebep-sonuç ilişkisine dayalı tahmin çalışması gerçekleştirilmiştir. YSA teorisi üzerinde araştırmalar yapılarak enerji alanında yaygın olarak kullanılan YSA ve tahmin modelleri incelenmiştir. Türkiye net enerji talebini tahmin etmek için literatürdeki çalışmalardan farklı olarak, net enerji talebini etkileyebilecek değişkenler dikkate alınarak YSA modeli kurulmuştur. Tahmin çalışmasının başarısını değerlendirebilmek ve performansını ölçebilmek için regresyon ve zaman seri modelleri geliştirilmiş ve kurulan YSA modeli ile karşılaştırmalar yapılmıştır.

YSA modelinde kullanılan bağımsız değişkenler, regresyon modelinde de kullanılmak istenmiş ancak regresyon modelinin gerekli istatistiksel varsayımları sağlamaması nedeniyle değişken azaltma ve transformasyon yöntemleri uygulanmıştır. İstatistiksel anlamlılığa sahip olan çoklu doğrusal regresyon modeli elde edildikten sonra, daha gerçekçi ve yorumlanabilir tahminler yapabilmek için regresyon modelinde kullanılan değişkenlerle yeni YSA modeli kurulmuş ve sonuçlar karşılaştırılmıştır. Yeni YSA modelinin çoklu doğrusal regresyon modeline göre daha başarılı sonuçlar verdiği saptanmıştır. Başlangıçta geliştirilen YSA modelinin ise yeni YSA modeline göre daha başarılı sonuçlar vermesiyle kullanılan bağımsız değişkenlerin modeli daha iyi ifade ettiği sonucuna ulaşılmıştır.

Yapılan analizler ve karşılaştırmalar neticesinde YSA tekniğinin daha başarılı tahminler gerçekleştirebildiği saptanmış olup 2011-2025 yılları için Türkiye net enerji talebi tahmin edilmiştir.

Bulunan tahmin değerleri gelecek yatırımların yönlendirilmesinde oldukça önemli olduğundan, karar vericilerin farklı tahmin çalışmalarını göz önünde bulundurarak karar vermeleri gerekmektedir. Bu sebeple farklı tahmin modelleri kullanılarak tahmin çalışmaları dikkate alınmalıdır. Bu çalışmada da Türkiye net enerjisi tüketimi tahmini için YSA modeliyle gerçeğe daha yakın sonuçlar elde edilerek karar vericilerin dikkatine sunulmaktadır. Bu çalışmanın sonuçları, başta Türkiye ETKB

olmak üzere enerji üretimi ile ilgili bütün kurumları ilgilendirmektedir. Elde edilen tahmin değerleri gelecek enerji politikalarının belirlenmesinde yardımcı olacaktır.

Gelecek çalışmalarda; modeli daha iyi ifade edecek değişkenler saptanarak geleceğe yönelik uzun dönemli ve kararlı tahmin çalışmaları gerçekleştirilecektir.

KAYNAKLAR

Akay D., Atak M., “Grey prediction with rolling mechanism for electricity demand forecasting of Turkey”, *Energy*, 32 : 1670-1675 (2007).

Baş N., “Yapay Sinir Ağları Yaklaşımı ve Bir Uygulama”, Yüksek Lisans Tezi, *Mimar Sinan Güzel Sanatlar Üniversitesi Fen Bilimleri Enstitüsü*, İstanbul, 17 (2006)

Bayır F., “Yapay Sinir Ağları ve Tahmin Modellemesi Üzerine Bir Uygulama”, Yüksek Lisans Tezi, *İstanbul Üniversitesi Sosyal Bilimler Enstitüsü*, İstanbul, 14 (2006).

Bessec M., Fouquau J., “The non-linear link between electricity consumption and temperature in Europe: a threshold panel approach” *Energy Economics*, 30(5) :2705–2721 (2008).

Bilgili M., Şahin B., Yaşar A., Şimşek E., “Electric energy demands of Turkey in residential and industrial sectors” , *Renewable and Sustainable Energy Reviews*, 16:404-414 (2012).

Canyurt O. E., Öztürk H. K., “Application of genetic algorithm (GA) technique on demand estimation of fossil fuels in Turkey”, *Energy Policy*, 36 : 2562–2569 (2008).

Ceylan H., Öztürk H. K., “Estimating energy demand of Turkey based on economic indicators using genetic algorithm approach” *Energy Conversion and Management*, 45 : 2525–2537 (2004).

Çağlar, T., “Talep Tahmininde Kullanılan Yöntemler ve Fens Teli Üretimi Yapan Bir İşletmede Uygulanması”, Yüksek Lisans Tezi, *Kırıkkale Üniversitesi Fen Bilimleri Enstitüsü*, Kırıkkale, 18-19 (2007).

Çakır, A. T.,” Türkiye’nin Enerji Potansiyeli, Dağılımı, İzlenilen Enerji Politikaları ile Bu Potansiyelin Kullanılması ve Türkiye’de Enerjinin Geleceği”,Yüksek Lisans Tezi, *Eskişehir Osmangazi Üniversitesi Fen Bilimleri Enstitüsü*, Eskişehir, 1-2 (2008)

Çınar D., Kayakutlu G., Daim T., “Development of future energy scenarios with intelligent algorithms: Case of hydro in Turkey”, *Energy*, 35 : 1724-1729 (2010).

Çuhadar M., ”Turizm Sektöründe Talep Tahmini için Yapay Sinir Ağları Kullanımı ve Diğer Yöntemlerle Karşılaştırmalı Analizi”, Doktora Tezi, *Süleyman Demirel Üniversitesi Sosyal Bilimler Enstitüsü*, Isparta, 63-64, (2006)

Demirel Ö., Kakilli A., Tektaş M., “Anfis ve Arma Modelleri İle Elektrik Enerjisi Yük Tahmini”, *Gazi Üniv. Müh. Mim. Fak. Der.*, 25 : 601-610 (2010).

Dilaver Z., Lester C. H., “Industrial electricity demand for Turkey: A structural time series analysis”, *Enerji Economics*, 33 : 426-436 (2011).

Dilaver Z., Lester C. H., “Turkish aggregate electricity demand: An outlook to 2020”, *Energy*, 36 : 6686-6696 (2011).

Duman N., “Yapay Sinir Ağları ve Bir Uygulama”, Yüksek Lisans Tezi, *Cumhuriyet Üniversitesi Sosyal Bilimler Enstitüsü*, Sivas (2006)

Ediger V. Ş., Akar S., “ARIMA forecasting of primary energy demand by fuel in Turkey”, *Energy Policy*, 35: 1701-1708 (2007).

Ediger V. Ş., Akar S., Uğurlu B., “Forecasting production of fossil fuel sources in Turkey using a comparative regression and ARIMA model”, *Energy Policy*, 34 : 3836-3846 (2006).

Ekonomou L., “Greek long-term energy consumption prediction using artificial neural networks”, *Energy*, 35 : 512-517 (2010).

Elmas Ç., “Yapay Sinir Ağları”, *Seçkin Yayıncılık*, Ankara, 27 (2003).

Elmas Ç., “Yapay Zeka Uygulamaları”, *Seçkin Yayıncılık*, Ankara, 25 (2007).

Erdoğan E., “Electricity demand analysis using cointegration and ARIMA modelling: A case study of Turkey”, *Energy Policy*, 35 : 1129-1146 (2007).

Erdoğan E., “Natural gas demand in Turkey”, *Applied Energy*, 87 : 211-219, (2010).

Fausett L., “Fundamentals of Neural Networks”, *Prentice-Hall*, New Jersey, 3 (1994).

Freeman, J.A., Skapura, D.M., “Neural Networks Algorithm, Applications and Programming Techniques”, *Addison-Wesley Publishing Company*, Boston, 6 (1991).

Filiz Ü. B., Gerek Ö. N., “A novel modeling approach for hourly forecasting of long-term electric energy demand”, *Energy Conversion and Management*, 52 : 199-211 (2011).

Geem Z.W., Roper W.E., “Energy demand estimation of South Korea using artificial neural network”, *Energy Policy*, 37 : 4049-4054, (2009).

Geem Z.W., ”Transport energy demand modeling of South Korea using artificial”, *Energy Policy*, 39 : 4644-4650 (2011).

Hagan M. T., Demuth H. B., Beale M., “Neural Network Design”, *PWS Publishing Company*, Boston, 3 (1996).

Haldenbilen S., Ceylan H., “Genetic algorithm approach to estimate transport energy demand in Turkey” *Energy Policy*, 33 : 89–98 (2005).

Hamzaçebi C., Kutay F.,” Yapay Sinir Ağları İle Türkiye Elektrik Enerjisi Tüketiminin 2010 Yılına Kadar Tahmini”, *Gazi Üniv. Müh. Mim. Fak. Der.*, 19 : 227-233 (2004).

Hamzaçebi C., “Forecasting of Turkey’s net electricity energy consumption on sectoral bases”, *Energy Policy*, 35 : 2009-2016 (2007).

Hamzaçebi, C., “Yapay Sinir Ağları: Tahmin Amaçlı Kullanımı Matlab ve Neurosolutions Uygulamalı”, *Ekin Yayınevi*, Bursa, 1-105 (2011).

Haykin, S., “Neural Network, A Comprehensive Foundation”, *Macmillan College Publishing Company*, New York , 5 (1994).

Hepbaşlı A., Özgener Ö., “ Turkey's Renewable Energy Sources: Part 1. Historical Development ” , *Energy Sources*, 26 : 961-969 (2004).

Himanshu A.A., Lester C.H. “Electricity demand for Sri Lanka: a time series analysis.” *Energy*; 33: 724–739 (2008).

İnternet : Enerji ve Tabii Kaynaklar Bakanlığı “ Enerji ”
<http://www.enerji.gov.tr/index.php?sf=webpages&b=enerji> (2011).

Kankal M., Akpınar A., Kömürcü M. İ., Özşahin T. Ş., “Modeling and forecasting of Turkey ’ s energy consumption using socio-economic and demographic variables“, *Applied Energy*, 88 : 1927-1939 (2011).

Kavaklıoğlu K., “Modeling and prediction of Turkey’s electricity consumption using Support Vector Regression”, *Applied Energy*, 88 : 368–375 (2011).

Kavaklıoğlu K., Ceylan H., Öztürk H. K., Canyurt O.E., “Modeling and prediction of Turkey ’ s electricity consumption using Artificial Neural Networks”, *Energy Conversion and Management*, 50 : 2719-2727, (2009).

Kıran M.S., Özceylan E, Gündüz M., Paksoy T.,” A novel hybrid approach based on Particle Swarm Optimization and Ant Colony Algorithm to forecast energy demand of Turkey”, *Energy Conversion and Management*, 53 : 75–83 (2012).

Kuyucuklu N., “Türkiye İktisadı”, *Filiz Kitabevi*, İstanbul, 415 (1993).

Küçükali S., Barış K., “Turkey’s short-term gross annual electricity demand forecast by fuzzy logic approach”, *Energy Policy*, 38 : 2438–2445 (2010).

Lee Y.S., Tong L.I., “Forecasting energy consumption using a grey model improved by incorporating genetic programming”, ***Energy Conversion and Management***, 52 : 147–152 (2011).

Limanond T., Jomnonkwao S., Srikaew A.,” Projection of future transport energy demand of Thailand”, ***Energy Policy***, 39 : 2754-2763 (2011).

Maier, H. R. and Dandy, G. C., “Neural networks for the prediction and forecasting of water resources variables: A review of modelling issues and applications”, ***Environmental Modelling & Software***, 15 : 101-124 (2000).

Mehrotra K., Mohan C. K., Ranka S., “Elements of Artificial Neural Networks”, ***A Bradford Book***, London, 5-6 (1997).

Murat Y. S., Ceylan H., “Use of artificial neural networks for transport energy demand modeling”, ***Energy Policy***, 34 : 3165–3172 (2006).

Öztemel E., “Yapay Sinir Ağları”, ***Papatya Yayıncılık***, İstanbul, 29-33(2003).

Öztürk H. K., Ceylan H., Hepbaşlı A., Utlü Z., “Estimating petroleum exergy production and consumption using vehicle ownership and GDP based on genetic algorithm approach”, ***Renewable and Sustainable Energy Reviews***, 8 : 289–302 (2004).

Sağiroğlu Ş., Beşdok E., Erler M., “Mühendislikte Yapay Zeka Uygulamaları-I, Yapay Sinir Ağları”, ***Ufuk Kitap Kirtasiye***, Kayseri, 24-25,33 (2003).

Sözen A., Arcaklıoğlu E., Özalp M., “Estimation of solar potential in Turkey by artificial neural networks using meteorological and geographical data” , ***Energy Conversion and Management***, 45 : 3033-3052 (2004).

Sözen A., Arcaklıoğlu E.,” Prediction of net energy consumption based on economic indicators (GNP and GDP) in Turkey”, ***Energy Policy***, 35 : 4981-4992 (2007).

Sözen A., Arcaklıoğlu E., Özkaymak M., “Turkey’s net energy consumption”, ***Applied Energy***, 81 : 209-221 (2005).

Suganthi L., Samuel A.A,” Energy models for demand forecasting-A review”, ***Renewable and Sustainable Energy Reviews***, 16 : 1223-1240 (2012).

Şahin, V., “Enerji Sektöründe Geleceğe Bakış”, ***Tüsiad Yayını***, İstanbul, 15 (1994).

Şen Z., “Yapay Sinir Ağları ve İlkeleri”, ***Su Vakfı Yayınları***, İstanbul, 9-10 (2004).

Toksarı M. D., “Ant colony optimization approach to estimate energy demand of Turkey”, ***Energy Policy***, 35 : 3984–3990 (2007).

Toksarı M. D., “Estimating the net electricity energy generation and demand using the ant colony optimization approach: Case of Turkey”, ***Energy Policy***, 37 : 1181–1187 (2009).

Ünler A., “Improvement of energy demand forecasts using swarm intelligence: The case of Turkey with projections to 2025”, ***Energy Policy***, 36 : 1937-1944 (2008).

Wang J, Zhu S., Zhang W., Lu H., “Combined modeling for electric load forecasting with adaptive particle swarm optimization” ***Energy***, 35(4) : 1671–1678 (2010).

Zhang G., Patuwo B.E., Hu M.Y., “Forecasting with Artificial Neural Networks:The State of the Art”, ***International Journal of Forecasting***, 14 : 35-62 (1998).

ÖZGEÇMİŞ

Kişisel Bilgiler

Soyadı, adı : ES, Hüseyin Avni
Uyruğu : T.C
Doğum tarihi ve yeri : 21.04.1986
Medeni hali : Evli
E-mail : h.avni.es@gmail.com

Eğitim Derece

Eğitim Birimi

Mezuniyet tarihi

Lisans	Gazi Üniversitesi/Endüstri Müh. Böl.	2010
Lise	Karabük Anadolu Öğretmen Lisesi	2006

Yabancı Dil

İngilizce

Hobiler

Futbol, gezi, bağlama çalma.