

**KARADENİZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

ENDÜSTRİ MÜHENDİSLİĞİ ANABİLİM DALI

YAPAY SINIR AĞLARI İLE İRAN ELEKTRİK TÜKETİM TAHMİNİ

YÜKSEK LİSANS TEZİ

End. Müh. Pegah MASAEBİ

**TEMMUZ 2016
TRABZON**



KARADENİZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

ENDÜSTRİ MÜHENDİSLİĞİ ANABİLİM DALI

YAPAY SİNİR AĞLARI İLE İRAN ELEKTRİK TÜKETİM TAHMİNİ

End. Müh. Pegah MASAEBİ

Karadeniz Teknik Üniversitesi Fen Bilimleri Enstitüsünce
"ENDÜSTRİ YÜKSEK MÜHENDİSİ"
Unvanı Verilmesi İçin Kabul Edilen Tezdir.

Tezin Enstitüye Verildiği Tarih : 24 / 05 / 2016

Tezin Savunma Tarihi : 11 / 07 / 2016

Tez Danışmanı : Doç. Dr. Şükrü ÖZŞAHİN

Trabzon 2016

**KARADENİZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

**Endüstri Mühendisliği Anabilim Dalında
Pegah MASAEBİ tarafından hazırlanan**

YAPAY SİNİR AĞLARI İLE İRAN ELEKTRİK TÜKETİM TAHMİNİ

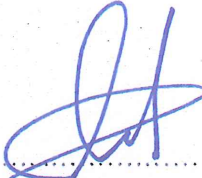
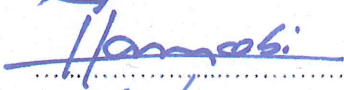
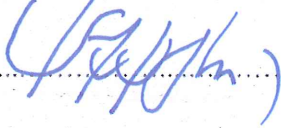
**başlıklı bu çalışma, Enstitü Yönetim Kurulunun 31 / 05 / 2016 gün ve 1655 sayılı
kararıyla oluşturulan jüri tarafından yapılan sınavda
YÜKSEK LİSANS TEZİ
olarak kabul edilmiştir.**

Jüri Üyeleri

Başkan : Prof. Dr. Cafer ÇELİK

Üye : Prof. Dr. Coşkun HAMZAÇEBİ

Üye : Doç. Dr. Şükrü ÖZŞAHİN


.....

.....

.....

Prof. Dr. Sadettin KORKMAZ

Enstitü Müdürü

ÖNSÖZ

Yapay Sinir Ağları ile İran Elektrik Enerjisi Tüketim Tahmini adlı bu çalışma Karadeniz Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Endüstri Mühendisliği Anabilim Dalı, Endüstri Mühendisliği Yüksek Lisans Tezi olarak hazırlanmıştır.

Tez çalışmasının planlanması, araştırılması, yürütülmesi ve oluşturulmasında ilgi ve desteğini esirgemeyen, bilgi ve tecrübelerinden yararlandığım danışman Hocam Sayın Doç. Dr. Şükrü ÖZŞAHİN'e sonsuz teşekkürlerimi sunarım.

Çalışmanın yürütülmesinde bilgi ve tecrübelerinden yararlandığım Hocam Sayın Prof. Dr. Coşkun HAMZAÇEBİ'ye ve Anabilim Dalımızda bulunan değerli hocalarıma teşekkür ederim.

Bu çalışmanın yürütülmesinde destek ve yardımlarını esirgemeyen Arş. Gör. Miraç MURAT'a teşekkür ederim.

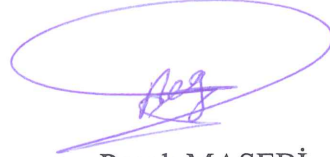
Maddi ve manevi yanımda olup desteklerini esirgemeyen değerli aileme sonsuz teşekkürlerimi sunarım.

Pegah MASAEBİ
Trabzon 2016

TEZ ETİK BEYANNAMESİ

Yüksek Lisans Tezi olarak sunduğum Yapay Sinir Ağları ile İran Elektrik Enerjisi Tüketim Tahmini başlıklı bu çalışmayı baştan sona kadar danışmanım Doç. Dr. Şükrü ÖZŞAHİN'in sorumluluğunda tamamladığımı, verileri kendim topladığımı ve başka kaynaklardan aldığım bilgileri metinde ve kaynakçada eksiksiz olarak gösterdiğimi, çalışma sürecinde bilimsel araştırma ve etik kurallara uygun olarak davrandığımı ve aksinin ortaya çıkması durumunda her türlü yasal sonucu kabul ettiğimi beyan ederim.

11/07/2016


Pegah MASEBİ

İÇİNDEKİLER

	<u>Sayfa No</u>
ÖNSÖZ.....	III
TEZ ETİK BEYANNAMESİ.....	IV
İÇİNDEKİLER	V
ÖZET	IX
SUMMARY	X
ŞEKİLLER DİZİNİ	XI
TABLolar DİZİNİ.....	XII
SEMBOLLER DİZİNİ	XIV
1. GENEL BİLGİLER.....	1
1.1 Giriş	1
1.2. Literatür Araştırması.....	2
1.3. Yapay Zeka.....	9
1.3.1. Yapay Zekanın Kronolojik Tarihçesi	11
1.4. Yapay Sinir Ağları.....	12
1.4.1. Yapay Sinir Ağlarının Tanımı	12
1.4.2. Yapay Sinir Ağlarının Tarihsel Gelişimi.....	13
1.4.3. Yapay Sinir Ağlarının Güçlü Yönleri.....	14
1.4.3.1. Doğrusal Olmama	14
1.4.3.2. Öğrenme	14
1.4.3.3. Genelleme	14
1.4.3.4. Uyarlanabilirlik.....	15
1.4.3.5. Hata Toleransı.....	15
1.4.3.6. Paralellik	15
1.4.3.7. Eksik Verilerle Çalışma.....	15

1.4.3.8.	Adaptasyon	16
1.4.4.	Yapay Sinir Ağlarının Zayıf Yönleri	16
1.4.5.	Yapay Sinir Ağlarının Kullanım Alanları	16
1.4.6.	Yapay Sinir Ağlarının Yapısı	17
1.4.6.1.	Biyolojik Sinir Hücresi	17
1.4.6.2.	Yapay Sinir Hücresi	18
1.4.7.	Yapay Sinir Ağlarının Temel Elemanları	20
1.4.7.1.	Girdiler	20
1.4.7.2.	Ağırlıklar	20
1.4.7.3.	Birleştirme Fonksiyonu	21
1.4.7.4.	Aktivasyon Fonksiyonu	22
1.4.7.5.	Çıktı	23
1.4.8.	Yapay Sinir Ağlarının Geleneksel Sistemlerden Farkları	23
1.4.9.	Yapay Sinir Ağlarının Tasarımı	24
1.4.9.1.	Normalizasyon	24
1.4.9.2.	Yapay Sinir Ağı Topolojisinin Seçimi	25
1.4.9.3.	Öğrenme Algoritmasının Seçimi	27
1.4.9.4.	Katman ve Nöron Sayısının Belirlenmesi	27
1.4.9.5.	Yapay Sinir Ağlarının Eğitimi ve Testi	27
1.4.9.6.	Eğitimin Sonlandırılması	28
1.4.9.7.	Performans Fonksiyonunun Belirlenmesi	29
1.4.9.8.	Diğer Etkenler	30
1.4.9.8.1.	Öğrenme Katsayısı	30
1.4.9.8.2.	Momentum Katsayısı	30
1.4.10.	Yapay Sinir Ağlarının Sınıflandırılması	31
1.4.10.1.	Türlerine Göre Yapay Sinir Ağları	31
1.4.10.2.	Öğrenme Yöntemine Göre Yapay Sinir Ağları	33

1.4.10.3.	Katman Sayılarına Göre Yapay Sinir Ağları	33
1.4.10.4.	Yapısına Göre Yapay Sinir Ağları.....	34
1.4.11.	Çok Katmanlı Algılayıcı.....	34
1.5.	Regresyon Analizi	38
1.5.1.	Regresyon Modelleri	38
1.5.2.	Basit Doğrusal Regresyon	39
1.5.3.	Çoklu Doğrusal Regresyon.....	41
1.6.	Temel Bileşen Analizi	42
1.6.1.	Temel Bileşen Analizinin Aşamaları.....	42
2.	YAPILAN ÇALIŞMALAR.....	44
2.1.	Veri Tabanı	44
2.2.	Yapay Sinir Ağı ile Tahmin.....	45
2.2.1.	Yapay Sinir Ağının Yapısı	45
2.2.2.	Yapay Sinir Ağı Modelinin Eğitim Sonuçları	46
2.2.3.	Yapay Sinir Ağı Modelinin Tahmin İşlemi	50
2.2.3.1.	Senaryolar	50
2.2.4.	Senaryolara Göre Yapay Sinir Ağı Tahmin Değerleri	52
2.2.5.	Yapay Sinir Ağı Modelinin Ağırlık Değerleri.....	52
2.3.	Yapay Sinir Ağı ile Zaman Serisi Tahmini	53
2.3.1.	Yapay Sinir Ağı Zaman Serisi Modelinin Yapısı.....	53
2.3.2.	Yapay Sinir Ağı Zaman Serisi Modelinin Eğitim Sonuçları	54
2.3.3.	Yapay Sinir Ağı Zaman Serisi Modelinin Ağırlık Değerleri.....	58
2.4.	Çoklu Doğrusal Regresyon Modeli	58
3.	SONUÇ VE ÖNERİLER.....	63
3.1.	Sonuç	63
3.2.	Öneriler	66
4.	KAYNAKLAR	67

ÖZGEÇMİŞ



Yüksek Lisans Tezi

ÖZET

YAPAY SİNİR AĞLARI İLE İRAN ELEKTRİK TÜKETİM TAHMİNİ

Pegah MASAEBİ

Karadeniz Teknik Üniversitesi
Fen Bilimleri Enstitüsü
Endüstri Mühendisliği Anabilim Dalı
Danışman: Doç. Dr. Şükrü ÖZŞAHİN
2016, 75 Sayfa

Sanayi ve teknolojinin gelişmesi ile elektrik enerjisine olan ihtiyaç her geçen gün artmaktadır. Artan enerji ihtiyacını karşılamak için enerji üretim, dağıtım ve iletim tesislerinin geleceğe dönük olarak planlanması gerekmektedir. Elektrik enerjisinin sağlıklı bir şekilde kullanılabilmesi için ihtiyaç olan miktarda üretilmesi gerekmektedir. Bunun için elektrik enerjisinde planlamaya gidilmektedir. Yapılacak tahminler ne kadar doğru olursa, yapılan planlama çalışmalarının da o kadar geçerli olacağı açıktır. Bu kapsamda, tez çalışmasında yapay sinir ağları (YSA) ile İran elektrik enerjisinin tüketim tahmini 1978-2014 yılları arasındaki veriler kullanılarak gerçekleştirilmiştir. Çalışmada kullanılan parametreleri; büyüme oranı, elektrik satış fiyatı, ithalat, ihracat, GSYH ve nüfus oluşturmaktadır. Kurulan YSA modellerinin başarısını ve tahmin performansını değerlendirmek için çoklu regresyon modelleri kurulmuş ve karşılaştırmalar yapılmıştır. Yapılan karşılaştırmalar sonucunda, YSA sebep sonuç, zaman serisi ve regresyon modellerinin MAPE oranı sırasıyla %1.76, %1.54 ve %2.07 olarak elde edilmiştir. Geliştirilen modellerle 2021 yılına kadar İran elektrik enerjisi tüketimi tahmin edilmiştir. Tahmin modellerinin sonuçları İran Enerji Bakanlığı'nın gelecek yıllardaki net elektrik tüketim tahmin değerleri ile de karşılaştırılmıştır.

Anahtar Kelimeler: Yapay sinir ağları, Elektrik enerjisi, Çoklu doğrusal regresyon, Zaman serileri

Master Thesis

SUMMARY

IRAN ELECTRIC ENERGY CONSUMPTION FORECASTING USING ARTIFICIAL
NEURAL NETWORK

Pegah MASAEBİ

Karadeniz Technical University
The Graduate School of Natural and Applied Sciences
Department of Industry Engineering
Supervisor: Assoc. Prof. Şükrü ÖZŞAHİN
2016, 75 Pages

Nowadays, with the development of industry and technology, electricity energy production has been highly increased. For meeting the increasing demand of energy, the distribution system and transmission facilities should be planned in a way that future priority has been taken into consideration. For accurate using of electricity energy, the produced energy amount has to be based on ordered aggregate. Thus, the electricity energy planning system is aimed to be well designed. Moreover as much as correctness of the estimation of energy production is acceptable, proposed plans will be more successful. In this work, Iran electricity energy consumption estimation is carried out by using of Artificial Neural Network (ANN) with data gathered between the years 1978-2014. The parameters used in this thesis are consumer electricity price, imports, exports, GDP, economic growth and population. In order to evaluate the success of ANN model and performance of estimation, multiple regression and time series models has been applied and comparisons has been made. The obtained MAPE ratio for results of ANN, ANN time series and multiple regression is 1.76%, 1.54% and 2.07% respectively. By using the developed model Iran electricity energy estimation was made up to 2021. Result of the estimation models were compared with future electricity forecasting values obtained from Iran ministry of energy.

Key Words: Artificial neural network, Energy, Multiple linear regression, Time series

ŞEKİLLER DİZİNİ

	<u>Sayfa No</u>
Şekil 1. Sinir hücresi	18
Şekil 2. Basit bir yapay sinir hücresi	19
Şekil 3. Çok katmanlı algılayıcı	20
Şekil 4. Eğitimin durdurulma bölgesi	29
Şekil 5. YSA'ların sınıflandırılması	31
Şekil 6. İleri beslemeli ağ yapısı	32
Şekil 7. Geri beslemeli ağ yapısı	33
Şekil 8. Elektrik tüketim tahmini için kurulan modelin yapısı	46
Şekil 9. Eğitim kümesine ilişkin hata performansı	47
Şekil 10. Öğrenme ve test kümelerine ilişkin regresyon grafikleri	47
Şekil 11. Gerçek değerler ile tahmin değerlerin kıyaslanması	48
Şekil 12. Zaman serisi tahmini için kurulan ÇKA	54
Şekil 13. Eğitim kümesine ilişkin hata performansı	54
Şekil 14. Öğrenme ve test kümelerine ilişkin regresyon grafikleri	55
Şekil 15. Gerçek değerler ile tahmin değerlerin kıyaslanması	55
Şekil 16. Durbin-Watson testi kararlarının şematik gösterimi	61

TABLolar DİZİNİ

	<u>Sayfa No</u>
Tablo 1. Biyolojik sinir ağı ve yapay sinir ağının karşılaştırılması.....	19
Tablo 2. Birleştirme fonksiyonu örnekleri	21
Tablo 3. Sık kullanılan aktivasyon fonksiyonları	22
Tablo 4. Geleneksel hesaplama yöntemleri ile YSA'ların karşılaştırılması.....	23
Tablo 5. Kullanım amaçlarına göre YSA topolojileri.....	26
Tablo 6. Geri yayılım için tanımlamalar	35
Tablo 7. Çalışmada kullanılan değişkenlere ilişkin bilgiler.....	44
Tablo 8. Modelde kullanılan eğitim ve test kümesi setleri ile tahmin modeli sonuçları	49
Tablo 9. Senaryolar ve yüzdelik değerler	50
Tablo 10 Düşük senaryo değerleri	51
Tablo 11 Beklenen senaryo değerleri	51
Tablo 12. Yüksek senaryo değerleri	51
Tablo 13. Farklı senaryolara göre elektrik tüketim tahmin değerleri	52
Tablo 14. YSA modelinin ağırlık değerleri	52
Tablo 15. Zaman Serisi tahmin modelinde kullanılan eğitim ve test kümesi verileri ile tahmin modeli sonuçları.....	56
Tablo 16. 2015 ile 2021 yılları tahmin işlemi için hesaplanan gecikmeler	57
Tablo 17. YSA zaman serisi modelinin tahmin değerleri.....	57
Tablo 18. Zaman serisi YSA modelinin ağırlık değerleri.....	58
Tablo 19. Regresyon modelinin sonuçları	59
Tablo 20. TBA sonucunda elde edilen özvektör değerleri	59
Tablo 21. TBA sonucunda elde edilen skorlar.....	60
Tablo 22. TBA bileşenleri ile kurulan regresyon modeli	61
Tablo 23. Regresyon analiz sonuçları.....	62
Tablo 24. TBA ile regresyon analizi sonucunda elde edilen tahmin değerleri.....	62
Tablo 25. ÇDR ve ZS yöntemlerinde test kümesi verileri için MAPE değerlerin kıyaslanması	63
Tablo 26. Sebep sonuç yönteminde test kümesi verileri için APE ve MAPE değerleri....	64
Tablo 27. Enerji bakanlığının değerleri ile kurulan modellerin sonuçlarının karşılaştırılması.....	65

Tablo 28. Enerji Bakanlıđının deđerleri ile kurulan modellerin APE ve MAPE kıyaslanması.....	65
--	----



SEMBOLLER DİZİNİ

BS	: Beklenen senaryo
BO	: Büyüme oranı
ÇDR	: Çoklu doğrusal regresyon
ÇKA	: Çok katmanlı algılayıcı
DE	: Diferansiyel evrim
DS	: Düşük senaryo
EB	: Enerji bakanlığı
ET	: Elektrik tüketimi
ESF	: Elektrik satış fiyatı
GA	: Genetik algoritma
GSMH	: Gayri safi milli hasıla
GSYH	: Gayri safi yurtiçi hasıla
GYA	: Geri yayılım ağları
MSE	: Hata kareleri ortalaması
HKT	: Hata kareleri toplamı
APE	: Ortalama yüzde hata
RMSE	: Karesel ortalama hata karekökü
MAPE	: Ortalama mutlak yüzde hata
TBA	: Temel bileşen analizi
TÜFE	: Tüketici fiyat endeksi
VIF	: Varyans artış faktörü
YS	: Yüksek senaryo
YSA	: Yapay sinir ağları
YZ	: Yapay zeka
ZS	: Zaman serisi

1. GENEL BİLGİLER

1.1 Giriş

İnsanoğlunun yaşamını devam ettirmesi ve hayatını kolaylaştırabilmesi için birçok önemli icat yapılmıştır. Modern hayatta bu icatların en önemlisi elektriktir. Thomas Edison, 1879 yılında elektrikli ampulü icat ederek insanlığa yol göstermiştir. Elektriğin hayatımızdaki önemini, yaşadığımız birkaç dakikalık elektrik kesintilerinde daha iyi anlarız.

Evrensel bir enerji kaynağı olmakla birlikte elektrik enerjisi; güneş enerjisi, hidroelektrik, rüzgar enerjisi, doğalgaz, termik gibi bileşenlerden elde edilmektedir. Hayatımızı kolaylaştıran ve hayatımızın büyük bir kısmını etkileyen tüm araçlarda elektrik enerjisi kullanılmaktadır (URL-1, 2015).

Sanayi ve teknolojinin gelişmesi ile elektrik enerjisine olan ihtiyaç her geçen gün artmaktadır. Artan enerji ihtiyacını karşılamak için enerji üretim, dağıtım ve iletim tesislerinin geleceğe dönük olarak planlanması gerekmektedir. Diğer yandan, küresel ısınma gibi çevresel etkiler ve enerjide dışa bağımlılık gibi siyasal sorunlar elektrik tüketiminde tasarruf gerekliliğini beraberinde getirmektedir. Bunun da en önemli yolu, elektrik enerjisinin, elektrik üretimi ile tüketimi arasındaki dengeyi sağlamaktır (Toker ve Korkmaz, 2011).

Elektrik enerjisi sektörünün sağlıklı gelişimi için talep, arz, iletim, dağıtım ve fiyatlandırma konularında planların yapılması büyük öneme sahiptir ve bunun için üretim, iletim ve dağıtım sistemlerinin geleceğe dönük planlanması gerekmektedir. Elektrik enerjisinin ihtiyaç miktarında üretilebilmesi için yapılacak doğru tahminler planlama çalışmalarının geçerliliğini de arttıracaktır (Hamzaçebi ve Kutay, 2004).

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

Nitel tahmin yöntemi, araştırmacının düşüncelerine bağlı bir tahmin yöntemidir. Yani aynı veriler için farklı kişiler farklı tahminlerde bulunabilir. Ancak uygulamasının kolay olması, fazla çaba ve zaman gerektirmemesi olumlu yanları olarak sayılabilir. Ayrıca bazı durumlarda zorunlu olarak nitel tahmin yöntemlerini kullanmak gerekebilir.

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 birisi olan yapay sinir ağları ile elektrik enerjisi alanında sebep-sonuç ilişkisine ve zaman serileri analizine dayalı tahmin çalışması gerçekleştirilmiştir.

Yapay sinir ağları (YSA), tahmin çalışmalarında oldukça başarılı sonuçlar vermektedir ve doğrusal olmayan problemleri modelleye bilmesiyle diğer tahmin yöntemlerinin önüne geçmektedir.

Bu çalışmanın birinci bölümünde literatür araştırması ve kullanılacak olan yapay sinir ağları ile çoklu regresyon yöntemi ayrıntılı bir şekilde anlatılmıştır. İkinci bölümde uygulama kısmı gerçekleştirilerek bulgular elde edilmiştir. Elde edilen sonuçların performansını değerlendirmek için çoklu doğrusal regresyon (ÇDR) modeli ile yapay sinir ağlarında sebep-sonuç ve zaman serisi (ZS) modelleri karşılaştırılmış ve 3 farklı senaryoya göre tahmin çalışması yapılmıştır. Üçüncü bölümde sonuçlar ve öneriler ortaya konulmuş ve değerlendirmeler yapılmıştır.

1.2. Literatür Araştırması

Elektrik enerjisi tüketim tahminine yönelik çalışmalar üç sınıfta değerlendirilebilir:

1. Kısa dönemli tahmin: saatlik, günlük veya haftalık.
2. Orta dönemli tahmin: aylık, üç aylık.
3. Uzun dönemli tahmin: yıllık veya daha uzun dönemler.

Yapılan birçok çalışma, geleceği tahminde, yapay sinir ağlarının en az geleneksel metotlar kadar, hatta daha iyi neticeler verdiğini göstermiştir. YSA'nın geleceği tahmin için kullanıldığı alanlardan biri de elektrik enerjisi tüketim tahminidir. Elektrik enerjisi

talep tahmini için YSA'nın kullanıldığı birçok çalışma mevcuttur (Hamzaçebi ve Kutay, 2004). Bunlardan bazıları aşağıda verilmektedir.

Park ve arkadaşları, elektrik yük tahmini için yapay sinir ağlarını kullanmışlardır. YSA geçmiş, hâlihazır ve gelecekteki sıcaklık ve yük ilişkilerini öğrenmek amacıyla kullanılmıştır. Bu makalede geçmiş tüketim verileri ve hava durumu verileri parametre olarak kullanılmıştır. Sonuçlar ortalama mutlak hata değeri açısından değerlendirilmiştir. Ortalama mutlak hata değeri %1.4 - 2.06 olarak elde edilmiştir (Park vd., 1991).

Lee ve arkadaşları, kısa vadeli elektrik yük tahmini için yapay sinir ağları yöntemini kullanmışlardır. Veriler hafta sonu ve hafta içi iki şablonda incelenmektedir. Bu makalede geçmiş, haftalık enerji tüketimi ve hava durumu, bağımsız parametreler olarak kullanılmıştır. Bir doğrusal olmayan model önerilmiştir ve yük tahmini için YSA'nın çeşitli yapıları uygulanmıştır. Ağ, bir ya da iki gizli katman ile ve çeşitli nöron kombinasyonları ile test edilmiştir ve sonuçlar tahmini hata açısından değerlendirilmiştir (Lee vd., 1992).

Moharari ve Debs, hafta sonu ve mevsimsel değişimlere göre özel ayarlanmış YSA tabanlı kısa vadeli elektrik yük tahmini ile ilgili bir çalışma yapmışlardır. Bu çalışmada nispeten küçük bir eğitim seti ile geri yayılım algoritmasını kullanarak elektrik yükü hafta sonu, hafta içi ve tatil günleri için mevsimsel etkiyi izleyerek, tahmin edilmiştir. Üç farklı veri seti YSA'ya tanımlanmıştır: hava durumu, mevsimsel faktör ve özel etkinlikler (tatil günleri veya hafta sonu). Sonuç olarak bu yaklaşım, hafta sonları ve tatil günlerinin yanı sıra hafta içi elektrik yük tahmin yeteneğine de sahiptir (Moharari ve Debs, 1993).

Mandal ve Sinha, çalışmalarında tekrarlayan YSA ile kısa vadeli yük tahminine çalışmışlardır. Tam tekrarlayan (Fully Recurrent or Complete Connectivity) (tam bağlanabilirlik) ve ileri beslemeli yöntem ile çeşitli ağlar modellenmiştir ve karakterleri tahmin işlemleri için kullanılmıştır. Girdi olarak sadece geçmiş tüketim verileri kullanılmıştır. Sonuç olarak eğitim ve test kümeleri için ortalama mutlak hata değeri, ağlarda %2 civarında elde edilmiştir (Mandal ve Sinha, 1995).

Voss ve arkadaşları, YSA ile düzelticiyi filtreme yöntemini (knowledge-based discrete time filtering) kullanarak elektrik yük tahmini için pratik bir yaklaşım sunmuşlardır. Bu makalede geçmiş enerji tüketimi, hava durumu, ekonomik gelişme gibi faktörler parametre olarak kullanılmıştır. Sonuçta ortalama hata ilk tahminlerde %3.24 - 9.55 arası elde edilmiştir. Hareketli ortalama metodu uygulandıktan sonra bu rakamlar %1.26 - 4.81 olarak elde edilmiştir (Voss vd., 1995).

Parlos ve arkadaşları, uzun dönemli elektrik yük tahmini için yapay sinir ağları, genetik algoritma ve bulanık mantık yöntemlerini beraber kullanarak melez bir model geliştirmişlerdir (Parlos vd.,1996).

AlFauhid ve arkadaşları, kısa vadeli elektrik yük tahmini için kademeli yapay sinir ağlarını kullanmışlardır. YSA kademeli öğrenim algoritması ile geçmiş elektrik yük ve hava durumu verileri kullanılarak, gelecek 24 saat için yarım saatlik enerji tahmini yapılmıştır. Son tahmin işlemi için zirve, minimum ve günlük enerji tahmini YSA ile yapıp son aşamada girdi olarak kullanılmıştır. Bu yöntemde tahmin-hata ortalamasının mutlak değerinin daha düşük olduğu tespit edilmiştir (Alfauhid vd., 1997).

Padmakumari ve arkadaşları, bulanık sinir ağları kullanarak uzun dönem elektrik yük tahmini yapmaya çalışmışlardır (Padmakumari vd., 1999).

Yalçınöz ve arkadaşları, Niğde'nin 1991 yılından itibaren, aylık enerji verilerinden faydalanarak çok katmanlı Perseptron YSA ve hareketli ortalama yöntemlerini kullanarak, Niğde bölgesinin 2001-2004 yılları için enerji tahminlerini gerçekleştirmişlerdir (Yalçınöz vd., 2002).

Marin ve arkadaşları, kısa vadeli elektrik yük tahmini için YSA kullanarak bir evrensel model geliştirmişlerdir. Model bir sonraki 24 saat için tam tüketim eğrisini tahmin etmektedir. Modelde 1989 - 1999 yılları İspanya merkez bölgelerine ait tüketim verileri kullanılmıştır. Sonuç olarak bu yöntemin, tahminin doğruluğu ve güvenilirliği açısından istatistiksel yöntemlere göre daha iyi olduğu ve çeşitli metrolojik durumlara ve sosyal ortamlara uyumlu olduğu görülmüştür (Marin vd., 2002).

Hsu ve Chen, yapay sinir ağları yaklaşımını kullanarak 2010 yılına kadar uzun dönem, saatlik elektrik yük tahmini yapmışlardır. Regresyon modeli ile YSA'nın sonuçları karşılaştırılmıştır ve YSA'nın daha doğru sonuçlar verdiği görülmüştür (Hsu ve Chen, 2003).

Hamzaçebi ve Kutay, uzun dönemli elektrik enerjisi tüketimi tahmininde yapay sinir ağlarını kullanmışlardır. 1970-2002 yılları arasındaki elektrik enerjisi tüketim değerleri ve nüfus bilgileri ile model kurulmuştur ve 2003-2010 arasındaki tahmin yapılmıştır. Yapay sinir ağları yöntemiyle bulunan sonuçlar, Box-Jenkins modelleri ve regresyon tekniği ile karşılaştırılmıştır. Sonuç olarak elektrik enerjisi tüketiminin tahmininde, yapay sinir ağları yönteminin iyi bir tahmin aracı olduğu saptanmıştır (Hamzaçebi ve Kutay, 2004).

Almamun ve Nagasaka, uzun vadeli elektrik talep tahmini için yapay sinir ağları yöntemini kullanmışlardır. Bu makalede nüfus, hane sayısı, yaz günleri, soğuk günler,

petrol fiyatı, elektrik fiyatı, sanayi üretim endeksi, gayri safi milli hasıla (GSMH), gayri safi yurtiçi hasıla bağımsız parametreler olarak kullanılmıştır. Önerilen yöntem YSA radyan tabanlı ağ fonksiyonudur. Sonuçta elektrik yük miktarının ekonominin bir yansıması olduğu kanıtlanmıştır (Almamun ve Nagasaka, 2004).

Almamun ve Nagasaka, uzun vadeli elektrik talep tahmini için yapay sinir ağları yöntemini kullanmışlardır. Bu makalede nüfus, hane sayısı, yaz günleri, soğuk günler, petrol fiyatı, elektrik fiyatı, sanayi üretim endeksi, gayri safi milli hasıla (GSMH), gayri safi yurtiçi hasıla bağımsız parametreler olarak kullanılmıştır. Önerilen yöntem YSA radyan tabanlı ağ fonksiyonudur. Sonuçta elektrik yük miktarının ekonominin bir yansıması olduğu kanıtlanmıştır (Almamun ve Nagasaka, 2004).

Sözen ve arkadaşları, Türkiye'nin net enerji tüketim tahmini için yapay sinir ağlarını kullanmışlardır. Bu makalede nüfus, brüt üretim, kurulu kapasite, ithalat ve ihracat parametreleri kullanılmıştır. Sinir ağlarını eğitmek için 2 model geliştirmişlerdir. Sonuç olarak elde edilen tahmin değerleri ile gerçek veriler karşılaştırılmıştır (Sözen vd., 2005).

Barzamini ve arkadaşları, yapay sinir ağı ile İran milli elektrik güç sisteminin kısa vadeli tahmini ile ilgili bir çalışma yapmışlardır. Bu makalede hafta içi ve hafta sonu elektrik tüketim verileri ve hava durumu parametre olarak kullanılmıştır. Sonuçta ortalama tahmin hataları ağustos 12'si ile 18'i arası %2-0.96 olarak ve eylül 23'ü ile 30'u arası %1.89 - 1.3 olarak elde edilmiştir (Barzamini vd., 2005).

Pao, çalışmasında Tayvan elektrik tüketimi tahmini için, doğrusal ve doğrusal olmayan istatistikî modeller ve YSA metodu ile birlikte, gayri safi yurtiçi hasıla, nüfus, milli gelir, tüketici fiyat endeksi gibi parametreleri kullanarak ekonometri modeli oluşturmuştur. Her iki modelde elektrik üretimini en çok etkileyen parametreler nüfus ve milli gelir, en az etkileyen parametre ise gayri safi yurtiçi hasıla olarak görülmüştür. Sonuçlar karşılaştırdığında YSA, elektrik tüketimi tahmin modelleri için doğrusal modellerden daha iyi sonuç vermiştir (Pao, 2006).

Sözen ve Arcaklıoğlu, Türkiye'nin net enerji tüketimini tahmin etmek için YSA yöntemini kullanmışlardır. Ekonomik göstergeler ve nüfus faktörlerini dikkate alarak 3 farklı model kurmuşlardır. Farklı modelleri karşılaştırarak gelecek için güvenilir sonuçlar elde etmeyi başarmışlardır (Sözen ve Arcaklıoğlu, 2007).

Romera ve arkadaşları, yapay sinir ağları yöntemi ile elektrik enerjisi aylık talep tahmini yapmışlardır. Bu makalede hava sıcaklığı, nem, aylık elektrik tüketimi, ekonomi ve teknoloji evrimi bağımsız parametreler olarak kullanılmıştır. Sonuç olarak elektrik

tüketiminin ekonomik ve teknolojik gelişimlerden dolayı arttığı görülmüştür. Ortalama mutlak hata yüzdesi, %2 olarak elde edilmiştir (Romera vd., 2007).

Azadeh ve arkadaşları, Elektrik enerji tüketimin tahmini için yapay sinir ağı ve genetik algoritması (GA) entegrasyonunu kullanmışlardır. Bu çalışmada 1981 ile 2005 yılları arası İran ziraat sektörünün elektrik tüketim (ET) bilgileri yer alır. Ekonomik parametreler; fiyat, katma değer, müşteri sayısı ve geçmiş dönemlerdeki tüketimden ibarettir. GA tüm parametreler için ayarlanmıştır ve minimum hataya sahip olan en iyi katsayılar belirlenmiştir. GA tahmin hatasının, regresyon yöntemi ile yapılan tahmin hatalarına göre daha az olduğu görülmüştür. Her bağımsız değişken tahmini için YSA kullanılmıştır ve daha sonra elektrik tüketim miktarı 2008 yılına kadar tahmin edilmiştir. GA ve YSA'nın, zaman serilerine göre daha az ortalama mutlak hata yüzdesine (MAPE) sahip olduğu ve YSA ile daha iyi sonuçlar elde edildiği görülmüştür (Azadeh vd., 2007).

Hamzaçebi çalışmasında Türkiye'nin 2020 yılına kadar sektörel bazdaki elektrik enerjisi tüketimini tahmin etmiştir. Bu tahminde, veri yapısındaki doğrusal olmayan ilişkileri modelleyen ve aynı zamanda birden fazla değişkenin gelecek değerlerini tahmin eden YSA yöntemi kullanılmıştır. Bu makalede sanayi, konut, tarım ve ulaştırma sektörlerin tükettiği enerji miktarı sebep sonuç modelinin girdi parametreleri olarak kullanılmıştır. Bulunan tahmin sonuçları resmi tahminlerle karşılaştırılmıştır (Hamzaçebi, 2007).

Azadeh ve arkadaşları, yüksek enerji tüketen endüstri sektöründe yıllık elektrik tüketim tahmini için yapay sinir ağları yöntemini kullanmışlardır. Enerji tüketiminin yüksek dalgalanmaları nedeni ile yüksek enerji tüketen sanayilerin enerji tüketim tahmini, geleneksel regresyon modeli ile mümkün değildir. YSA kısa süreli tahminler için kullanılmasına rağmen, bu çalışma sanayilerde yıllık tahminlerin yapılmasının mümkün olduğunu göstermektedir. Sonuç olarak tahminlerin daha az hata ile yapılmasını sağlayan çok katmanlı algılayıcı (ÇKA) yöntemi kullanılmıştır. YSA analizinin avantajını göstermek amacıyla varyans analizi (ANOVA) uygulanmıştır ve sonuçlar regresyon analizi ile karşılaştırılmıştır. 1979 – 2003 yılları arası İran sanayi elektrik tüketim bilgileri veri olarak kullanılmıştır. Bu makalede her sektörün elektrik fiyatı, her sektör için abone sayısı, fosil yakıtların ortalama fiyat ağırlıkları, her sektör için elektrik tüketimi, her sektör için katma değer ve endüstrilerde tüketilen elektrik enerjisinin yoğunluğu parametreleri kullanılmıştır (Azadeh vd., 2008).

Zhang ve arkadaşları, YSA yöntemini kullanarak kısa vadeli elektrik yük tahmini ile ilgili bir çalışma yapmışlardır. Bu makalede kısa vadeli tahmin işlemi için ileri beslemeli, geri yayımlı ağ kullanılmıştır. Daha dikkatli tahmin yapılması amacıyla veriler üç bağımsız gruba ayrılmıştır: iş günü verileri, hafta sonu verileri ve festival verileri. Modelde Nanchang şehrinin iki senelik gerçek verileri kullanılmıştır. Sonuçta 2004 yılının elektrik yük tahmini yapılmıştır ve kabul edilebilir seviyede sonuçlar elde edilmiştir (Zhang vd., 2008).

Kavaklıoğlu ve arkadaşları, Türkiye elektrik tüketiminin modellenmesi ve tahmini için çok katmanlı algılayıcı yapay sinir ağlarını kullanmışlardır. Gayri safi yurtiçi hasıla, nüfus, ithalat ve ihracat miktarı gibi ekonomik faktörlerden YSA modellemesinde yararlanmışlardır. Sonuç olarak gelecekteki elektrik tüketiminin YSA ile tahmin edilmesinin mümkün olduğunu göstermişlerdir (Kavaklıoğlu vd., 2009).

Geem ve Roper, Kuzey Kore enerji talebinin tahmini için yapay sinir ağlarını kullanmışlardır. Modelde dört bağımsız değişken kullanılmıştır: gayri safi yurtiçi hasıla, nüfus, ithalat, ihracat. Önerilen model ortalama karekök hata açısından regresyondan (çoklu doğrusal değişkenli ve en küçük kareler metodu) veya üstel metottan (Karışık tamsayı değişkenleri, dal ve sınır yöntemi, Broyden–Fletcher–Goldfarb–Shanno) daha iyi sonuç vermiştir (Geem ve Roper, 2009).

Ghanbari ve arkadaşları, yapay sinir ağları ve regresyon analizini kullanarak, İran için elektrik yük tahmini yapmışlardır (Ghanbari vd., 2009).

Hahn ve arkadaşları, üç dönem (kısa vadeli: ilerideki 1 günden 1 haftaya kadar; orta vadeli: ilerideki 1 haftadan 1 yıla kadar, uzun vadeli: ilerideki 1 yıldan 20 yıla kadar) için de elektrik yük tahmini yapmış ve yöntem olarak regresyon analizi, zaman serileri analizi ve yapay sinir ağlarını kullanmışlardır (Hahn vd., 2009).

Ekonomou, 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 verileri kullanılarak 2010, 2012 ve 2015 yılları için toplam enerji tüketimi tahmin edilmiştir. Elde edilen sonuçlar, destek vektör ve regresyon modelleri ile karşılaştırılarak kurulan modelin başarısının iyi bir düzeyde olduğu görülmüştür (Ekonomou, 2010).

Eke ve arkadaşları, Türkiye'nin orta dönem elektrik yük tahmininde yapay sinir ağları yöntemini kullanmışlardır. Bu çalışma diferansiyel evrim algoritması (DE) ile yapay sinir ağlarının karma bir çalışmasını, yük tahmini için DE-YSA olarak sunar. Çalışma,

yapay sinir ağırları eğitiminde, DE algoritmasının performansını test etmektedir (Eke vd., 2011).

Dilaver ve Lester, Türkiye'nin gelecek elektrik enerjisi talebini tahmin etmek için zaman serisi yaklaşımını kullanmışlardır. Bu makalede toplam elektrik enerjisi tüketimi, GSMH ve elektrik fiyatları arasındaki ilişkiyi araştırmışlardır. 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 trendinin, Türkiye elektrik enerjisi talebinde önemli etkenler olduğu görülmüştür (Dilaver ve Lester, 2011).

Kankal ve arkadaşları, Türkiye'nin enerji tüketiminin modellenmesi ve tahmini için sosyoekonomik ve demografik değişkenleri kullanmışlardır. Türkiye enerji tüketim miktarı; gayri safi yurtiçi hasıla (GSYH), nüfus, ithalat-ihracat miktarı, iş parametreleri kullanılarak yapay sinir ağırları ve regresyon analizi ile ilgili tahmin yürütülmeye çalışılmıştır. Tahmin işlemi için 4 farklı model kullanılmıştır ve sonuç olarak 4 bağımsız değişkene (gayri safi yurtiçi hasıla, nüfus, ithalat ve ihracat) sahip olan model, diğer modellere göre daha iyi sonuç vermiştir. Sonuçların doğruluğunu test etme amacı için resmi kurumların tahminleri ile karşılaştırmalar yapılmıştır (Kankal vd., 2011).

Buhari ve Adamu, yapay sinir ağırları yöntemini kullanarak, Nijerya için elektrik yük tahmini yapmışlardır (Buhari ve Adamu, 2012).

Bilgili ve arkadaşları, Türkiye konut ve sanayi elektrik enerjisi talep tahmini ile ilgili bir çalışma yapmışlardır. Bu çalışmada enerji tahmini için YSA, doğrusal ve doğrusal olmayan regresyon modellerini kullanmışlardır. Kurulu kapasite, elektrik üretimi, nüfus ve toplam konut ve sanayi aboneleri bağımsız değişkenler olarak kullanılmıştır. Güçlü ve zayıf başlıklı iki senaryo belirlenmiştir. Belirlenen üç yöntemden elde edilen sonuçlar birbiri ile ve enerji bakanlığı tarafından verilen bilgiler ile karşılaştırılmıştır. YSA yönteminin diğer yöntemlere göre daha uygun olduğu görülmüştür (Bilgili vd., 2012).

Fan ve arkadaşları, yapay sinir ağırlarını kullanarak Avustralya için kısa dönem elektrik yük tahmini gerçekleştirmişlerdir (Fan vd., 2012).

Moturi ve Kioko, Kenya'nın kısa dönem elektrik yük tahminini yapmışlardır. Tahmin için yapay sinir ağırlarını farklı iterasyonlarda kullanmışlardır. İdeal iterasyonlarda sonuçlar istenildiği gibi çıkmıştır (Moturi ve Kioko, 2013).

Asare-Bediako ve arkadaşları Smart Meter verilerini kullanarak YSA ile bir sonraki gün için konut (elektrik) yük tahmini ile ilgili bir çalışma yapmışlardır. Bir sonraki gün

yük tahmini için, hava durumu verileri ve Smart Meter geçmiş verileri kullanılarak YSA yöntemi uygulanmıştır. Sonuç olarak modelin uygunluğunu test etmek amacı ile çeşitli hata analizleri yapılmıştır (Asare-Bediako vd., 2013).

Zahedi ve arkadaşları, Kanada Ontario eyaletinin elektrik talep tahmini için, sinir bulanık ağını kullanmışlardır. Bu makalede 1976 – 2005 yılları arası Ontario eyaletinin elektrik talebi adaptif sinirsel bulanık çıkarım sistemi ile modellenmiştir. İstihdam sayısı, gayri safi yurtiçi hasıla, nüfus, konut sayısı ve hava sıcaklığı ile ilgili iki meteorolojik girdi, parametre olarak kullanılmıştır. Sonuç olarak istihdam değişkeni elektrik talebini en çok etkileyen parametre olarak görülmüştür (Zahedi vd., 2013).

Uzlu ve arkadaşları, Türkiye'nin enerji tüketim tahmini için YSA modeli ile öğretmenli – öğrenme optimizasyon algoritmasını kullanmışlardır. Modelin performansı ve doğruluğunun değerlendirilmesi için klasik eğitimli geri yayılım modeli kurulmuş ve önceki modellerle çeşitli hata kriterlerine göre karşılaştırılmıştır. Sonuç olarak YSA modelindeki eğitim ve test hatalarına göre, öğretmenli – öğrenme YSA modelinin iyi bir sonuç üretmediği görülmüştür. Gayri safi yurtiçi hasıla, nüfus, ithalat ve ihracat bağımsız parametre olarak kullanılmıştır (Uzlu vd., 2014).

Kialashaki ve Reisel, ABD sanayi sektöründeki enerji talep tahmini için yapay sinir ağları yöntemini kullanmışlardır. Bu makalede ABD enerji talep tahmini için YSA ve çoklu doğrusal regresyon modeli kurulmuştur. Gayri safi yurtiçi hasıla ve enerji taşıyıcıların fiyatları gibi bağımsız değişkenler parametre olarak kullanılmıştır. Modelde etkileyici bağımsız değişkenlerin tahmin süresince sabit olduğu ve sadece gayri safi yurtiçi hasıla değişkeninin ikinci derece polinom eğilimi ile arttığı varsayılmıştır. Sonuçlar ABD Enerji Bakanlığı bilgileri ile karşılaştırılmıştır ve tutarlılığı görülmüştür (Kialashaki ve Reisel, 2014).

Var ve Türkay, yapay sinir ağları yöntemini kullanılarak, İstanbul'daki bir bölgenin elektrik puant yükünü tahmin etmişlerdir (Var ve Türkay, 2014).

1.3. Yapay Zeka

Yapay zekâ (YZ) ile ilgili çalışmalar McCulloch ve Pitts tarafından 1940'lı yıllarda yapılmıştır. YZ, zekâ ve düşünmeye ihtiyaç duyan işlemlerin bilgisayar ile yapılmasının sağlanması ve yeni yöntemlerin geliştirilmesiyle ilgili bir bilim dalıdır. Yapay zekâ; “düşünme, anlama, kavrama, yorumlama ve öğrenme yapılarının, programlamayla taklit

edilerek, problemlerin çözümüne uygulanması'' olarak da ifade edilebilir (Sağıroğlu vd., 2003). Bilgisayarlar, olaylar hakkında karar vererek, olaylar arası ilişkiyi de ortaya koymaktadırlar. Matematiksel yöntemlerle formüle edilemeyen ve çözümsüz olan problemler, sezgisel metotlar kullanılarak bilgisayar ile çözülebilir. 60'dan fazla yapay zekâ teknolojilerinden bahsedilir. Bu teknolojilerin birçoğu henüz laboratuvar aşamasında olup, laboratuvar düzeyini aşan ve günlük hayatta kullanılan teknolojilerin bir kaç tanesi aşağıda verilmektedir (Öztemel, 2012).

Uzman Sistemler: Kişilerden toplanan bilgileri temel alarak, belirli bir uzmanlık alanında, zamanla kendisini geliştirebilme yeteneği de olan yazılımdır. Uzman Sistem geliştirilirken, uzmanların belli bir konudaki bilgi ve deneyimlerini bilgisayara aktarılması amaçlanmaktadır. Uzman davranışlarını taklit etmek üzere çok farklı yöntemler kullanılmakla birlikte, en çok kullanılanlar bilgi temsili yöntemleri ve bilgi mühendisliği yöntemleridir (Elmas, 2011). Bunu bir tür bilgisayarda düzenlenmiş danışma sistemi olarak düşünebiliriz. Uzman sistemler hem makine hem de insan müdahalesine ihtiyaç duyan uygulamalarda kullanılır (Tektaş vd., 2002).

Bulanık Mantık: Bulanık mantığın temeli bulanık küme ve alt kümelerdir. Klasik kümelerde bir varlık ya kümenin elemanıdır ya da değildir. Matematiksel olarak ifade edildiğinde, kümenin elemanı olduğunda "1", kümenin elemanı olmadığıda "0" değerini alır. Bulanık mantık klasik küme gösteriminin genişletilmiş halidir. Bulanık kümesinde her bir varlığın bir üyelik derecesi vardır. Klasik kümelerin aksine bulanık kümelerde elemanların üyelik dereceleri $[0, 1]$ aralığında değişebilmektedir. Bulanıklık net olmama durumudur ve bir belirsizlik çeşididir. Bulanık mantık insan mantığında olduğu gibi, uzun-kısa, siyah-beyaz, az soğuk-soğuk-çok soğuk vb. gibi ara değerlere göre çalışmaktadır (Elmas, 2011).

Genetik Algoritma: Doğal seçim ilkelerine dayanan bir arama ve optimizasyon yöntemi olan genetik algoritmanın (GA) temel ilkeleri John Holland tarafından ortaya atılmıştır (Horat, 2014). Genetik algoritma Darwin'in evrim teorisine dayanan bir arama ve optimizasyon yöntemidir. Bu teoride çevre koşullarına ayak uyduran canlılar yaşar, uyduramayanlar ölür. Bu algoritmanın temel dayanağı, evrimin temel yasalarına dayanmaktadır. Her zaman sadece en iyi olan yaşar ve çoğalır. Genetik algoritma çözümü çok zor olan problemlerin çözümünde kullanılmaktadır (Elmas, 2011).

Yapay Sinir Ağları: YSA, insan beyninin öğrenme, hatırlama, genelleme yapma özelliklerini taklit ederek yeni bilgiler üretebilmektedir. YSA biyolojik sinir ağlarını taklit

eden sentetik yapılardır. Yapay sinir ağları ile konu hakkında bilgiler alındıktan sonra örnekler üzerinde eğitimler gerçekleştirilerek ve genelleştirmeler yapılarak, daha sonraki olaylar ile ilgili çözümler üretilebilmektedir (Ertunç, 2006).

1.3.1. Yapay Zekanın Kronolojik Tarihçesi

1943: McCulloch ve Pitts: Beynin Boolean devre modelinin tanımı.

1950: Turing'in bilgi işleyen makineler ve zeka konusunu ortaya atması.

1956: Dartmouth Görüşmesi: "Yapay Zeka" isminin ortaya atılışı.

1952-1969: IBM satranç oynayabilen ilk programı yazdı. YZ konusundaki ilk uluslararası konferans.

1950'ler: İlk YZ programları, Samuel'in kontrol edici programı, Newell ve Simon'ın mantık teorisi, Gelernter'in geometri motoru.

1965: Robinson'un mantıklı düşünme için geliştirdiği tam algoritma.

1966-1973: YZ hesapsal karmaşayla karşılaşır. Sinir ağları araştırmaları hemen hemen kaybolur.

1969-1979: Bilgiye dayalı sistemlerin ilk gelişme adımları.

1980: YZ'nin endüstri haline gelişi.

1986: Yapay sinir ağlarının tekrar popüler oluşu.

1987: YZ'nin bilim haline gelmesi.

1995: Zeki ajanların (terimsel kullanımdır) ortaya çıkışı.

1997: Satranç oyununda Deep Blue'nun Kasparov'u yenmesi.

1998: İnternetin yaygınlaşp YZ tabanlı birçok programın geniş kitlelere ulaşması.

2000-2005: Robot oyuncakların piyasaya sürülmesi (Helvacı, 2007).

2006: Bio fizik benzetimi ve nöromorfik hesaplamalar için yarı iletken bütünleyici metal oksit tabanlı hesaplama cihazları (Yang vd., 2008).

2007: Dama oyunu Alberta üniversitesi araştırmacıları tarafından çözülmüştür.

2009: Kendi kendine sürüş yapan arabaların google tarafından geliştirilmesi (URL-2, 2016)

2010: Xbox 360 için Microsoft launched Kinect; üç boyutlu kamera ile uzaktan insan hareketlerini tarayarak oyuncunun kablosuz ve kumandasız bir şekilde oyun oynaması (URL-3, 2015).

2011: Apple firması tarafından geliştirilen kullanıcı konuşmasını anlayarak ona uygun cevap veren Siri programı.

2013: Carnegie Mellon üniversitesi tarafından farklı fotoğrafları bir biri ile karşılaştıran sonsuz imaj öğrenme adlı program.

2015-2016: Google DeepMinde'ın AlphaGo takımı 3 kez Avrupa profesyonel şampiyonu Fan Hui yenmiştir (URL-4, 2016).

1.4. Yapay Sinir Ağları

1.4.1. Yapay Sinir Ağlarının Tanımı

Bazı bilim adamları tarafından yapılmış olan tanımlar aşağıdaki gibidir.

Yapay sinir ağları, insan beyninin özelliği olan öğrenme yolu ile yeni bilgiler üretebilmek ve keşfedebilmek gibi yetenekleri, otomatik olarak ve yardımsız bir şekilde yapabilen bilgisayar sistemidir. Bilgisayarların öğrenebileceği ve olaylar hakkında bilgileri olmadığı ya da eksik olduğu durumlarda veya örneklerin olduğu durumlarda çok etkin olarak yararlanabilecek bir karar verme aracıdır ve hesaplama yöntemi olarak bahsedilebilir (Öztemel, 2012).

Yapay sinir ağları yöntemi, doğrusal olmayan ve değişken davranışlar nedeniyle doğrusal yöntemlere göre daha iyi çözümler üretebilmektedir (Clarkson, 1999). Yapay sinir ağı, insan beynindeki hesaplamalardan örnek alınarak yapılan bir yöntemdir. İnsan beyninde yapılan hesaplamalar, geleneksel dijital bilgisayarlardaki hesaplama yöntemlerinden tamamen farklı olmaktadır. Beyin çok karmaşık, doğrusal olmayan ve paralel bir bilgisayardır. Beyin kendi bileşenlerini (sinir hücrelerini) bir hesaplama yapmak amacıyla organize etme yeteneğine sahiptir. Örnek olarak, beyin bir resim tanıma ve hatırlama, algı ve motor kontrolü gibi işlemleri günümüzdeki bilgisayarlardan çok daha hızlı olarak yapabilmektedir. Veya bir karmaşık görüntüyü görmek ve hatırlamak, daha sonra farklı zaman ve yerde aynı görüntüyü hatırlamak 0,1 – 0,2 saniye süresinde beyinde gerçekleşiyor, hâlbuki bu işlem bilgisayarlarda saatlerce sürebilen bir işlemdir (Haykin, 1994). YSA insan beyninin biyolojik sınırlarından esinlenen genelleştirilmiş matematiksel bir modeldir (Fausett, 1994).

1.4.2. Yapay Sinir Ağlarının Tarihsel Gelişimi

İlk başlarda bilgisayarlar sadece aritmetik işlemler yapmak için tasarlanmıştır ama günümüzde olayları öğrenmeleri ve çevre şartlarına göre karar vermeleri istenmektedir. Yapay sinir ağları günümüzde bu gelişmeyi tetikleyen bilim dallarından birisidir.

YSA ile ilgili çalışmalar, 1970 öncesi ve sonrası olarak ikiye ayrılmaktadır.

1970 öncesinde olan gelişmeler şöyle özetlenir:

İlk yapay sinir ağı modeli 1943 yılında, Warren McCulloch ve Walter Pitts tarafından geliştirilmiştir ve biyolojik sinir hücresinin ilk yapay modeli ortaya koyulmuştur (Elmas, 2003).

1949 yılında Hebb, hücre bağlantılarını ayarlamak için, ilk öğrenme kuralını önermiştir. Rosenblatt 1962 yılında, algılayıcı modeli ve öğrenme kuralını geliştirmiştir. 1960-1962 yılında, Widrow ve Hoff tarafından ADALINE'lar ve öğrenim yönetim sistemi (LMS) kuralı geliştirilmiştir.

1970 sonrasında olan gelişmeler ise:

Kohonen 1972 yılında Korelasyon Matris Belleğini geliştirmiştir. Fukushima, 1980'lerin başında görsel şekil ve yapıları tanımlamak amacıyla geliştirdiği Neocognitron modelini tanıtmıştır. 1982 ve 1984 yıllarında John Hopfield, yapay sinir ağlarının farklı bir matematiksel modelini üretmiştir. 1982 yılında Kohonen, öğretmensiz öğrenme modelinin gelişmesine katkıda bulunmuştur. 1986'da Rummelhart, Hinton, Williams ve McClelland, Geri Yayılım Algoritmasını ortaya çıkarmışlar ki bu teknik, tek katmanlı ağların çözemediği problemleri, çok katmanlı ağlar ile çözebildiğini ortaya koymuştur. 1988'de Broomhead ve Lowe, Radyal Tabanlı Fonksiyonlar modelini geliştirmişlerdir. Broomhead ve Lowe, makalelerinde radyal tabanlı fonksiyon temelli yapay sinir ağlarını, çok katmanlı ağlara alternatif olarak geliştirdiklerini belirtmişlerdir. 1990'da Daniel Spect, olasılıksal sinir ağlarını geliştirmiştir. Specht, 1991 yılında, genelleştirilmiş regresyon ağlarını geliştirmiştir (Yücesoy, 2011).

2009 ile 2012 yıllarında Jürgen Schmidhuber tarafından, tekrarlayan sinir ağları (Recurrent Neural Network) ve derin ileri beslemeli sinir ağları ile geliştirilen örüntü tanıma ve makine öğrenimi modelleri ile sekiz uluslararası ödül kazanılmıştır (URL-5, 2016). Örneğin; Alex Graves et al, 2009 yılında üç farklı dilde birleşik el yazımı metinleri dillerin hiçbiri programa tanımlı olmamasına rağmen tanıyan bir program geliştirdi (Graves ve Schmidhuber, 2009).

1.4.3. Yapay Sinir Ağlarının Güçlü Yönleri

Yapay sinir ağları öngörü, tahmin ve öğrenme gibi yeteneklere sahip olduklarından istatistiki yöntemlere göre daha kolay çözüm üretebilirler, özellikle doğrusal olmayan sistemler, geleneksel sistemlerden daha fazla avantajlara sahiptirler. Bunun için işletmelerde, finans sektöründe ve birçok farklı alanlarda kullanım imkânı bulurlar. Bu noktada sinir ağları kavramını çekici kılan temel özellikler sırasıyla aşağıdaki gibi incelenebilir:

1.4.3.1. Doğrusal Olmama

YSA'nın doğrusal ya da doğrusal olmayan problemler için tercih edilen aktivasyon fonksiyonu sayesinde, iyi çözümlere ulaşılabilmektedir. Günlük yaşamda karşılaşılan birçok problem, doğrusal olmadığından dolayı, yapay sinir ağlarının bu tip konularda önemi anlaşılabilir (Haykin, 1994).

1.4.3.2. Öğrenme

Yapay sinir ağlarının öğrenme sistemi, insan beyninin çalışma şekline benzemektedir. Yapay sinir ağları yönteminde elde edilen probleme ilişkin veriler kullanarak veri yapısındaki saklı ilişkiler ortaya çıkarılmaya çalışılır (Hamzaçebi, 2011).

YSA'lar, örnekleri kullanarak probleme ilişkin genelleme yeteneğine sahiptirler. Kendisine gösterilen yeni örnekleri öğrenebilmeleri ve yeni durumlara adapte olabilmeleri sayesinde, sürekli olarak yeni olayları kavrayabilmektedirler.

1.4.3.3. Genelleme

Ağ yapısının, eğitim sırasında kullanılan nümerik verilerde eşleştirmeyi sergileyebilmesi, kaba veya kullanılmayan özelliklere sahip olan verileri ayırt etmesi ve bunlarla anlamlı bir sonuç üretebilmesidir (Efe ve Kaynak, 2006).

1.4.3.4. Uyarlanabilirlik

Belirli bir problemi çözmek için eğitilen YSA, problemdeki değişimlere göre tekrar eğitilebilir ve değişimler devamlı ise gerçek zamanda denetim gibi alanlarda etkin olarak kullanılır (Ergezer vd., 2003).

1.4.3.5. Hata Toleransı

YSA, birçok sayıda hücrenin bağlanmasından oluşmaktadır ve paralel bir şekilde dağılmıştır. Ağa giren bilgiler, bütün bağlantılar üzerine dağılmaktadır. Bu nedenle, YSA'nın eğitiminde bazı hücrelerin etkisiz hale gelmesi, ağın doğru bilgi üretmesini önemli bir seviyede etkilemez. Bunun için, geleneksel yöntemlere göre hatayı tolere etme yeteneği daha fazladır (Bahadır, 2008). Ağdaki girdi bilgilerinde bulunabilecek herhangi bir gürültü bütün ağırlıklar üzerine dağıtıldığından, gürültü etkisi tolere edilebilir (Eroğlu, 2006).

1.4.3.6. Paralellik

YSA'lar birçok hücreden meydana gelir ve bu hücreler eş zamanlı çalışarak karmaşık işlevleri yerine getirirler. Geleneksel yöntemlerin çoğunda işlemler seri bir düzen içerisinde. Bu düzen hız sorunu oluşturmaktadır. Bilgisayarların beyne göre çok daha hızlı olmalarına rağmen, beynin toplam hızı bilgisayarlara göre çok daha yüksektir. YSA'larda aynı katmanda zaman bağımlılığı da bulunmamaktadır. Bu durum, tüm sistemin eş zamanlı ve hızlı çalışabilmesine olanak vermektedir. Bu sayede doğrusal olmayan problemlerin de çözülmesi mümkündür (Temür, 2013).

1.4.3.7. Eksik Verilerle Çalışma

YSA, geleneksel sistemlerin aksine, eksik bilgilerle de çalışabilmekte ve sonuç üretebilmektedir. Modelin performansı ise eksik bilgilerin önemine bağlıdır (Yiğit, 2011).

1.4.3.8. Adaptasyon

Yapay sinir ağlarının kendisine gösterilen örnekler ile yeni durumlara adapte olması ve yeni olayları öğrenebilmesi mümkündür (Öztemel, 2006).

YSA'lar, tanımı ya da parametreleri değişen probleme veya sisteme uygun çözümler üretebilmek için tekrar tekrar eğitilebilirler. Eğitim gerçek zamanda da gerçekleştirilebilir (Sağiroğlu, 2003).

1.4.4. Yapay Sinir Ağlarının Zayıf Yönleri

Yapay sinir ağlarının bazı dezavantajları aşağıdaki gibidir:

- Sistem içerisinde ne olduğu bilinemez.
- Farklı sistemlere uyarlanması zor olabilir (Elmas, 2011).
- Örneklerin bulunmasının zor olduğu ya da doğru örnekler için karar verilemediği durumlarda sağlıklı çözüm üretilememektedir. Ağ nümerik olan veriler ile çalışabilmektedir. Bu yüzden bilgilerin normalize edilmesi gerekir ve bu da ağın performansını doğrudan etkileyecektir. Bu durum ise kullanıcının yeteneğine bağlıdır.

- YSA'ların en önemli sorunu donanıma bağımlı olmalarıdır.

- Uygun ağ yapısının belirlenmesinde belli bir kural yoktur. Uygun ağ yapısı, deneme yanılma yolu ile belirlenmektedir. Eğer problem için uygun bir ağ oluşturulamazsa, performansı düşük bir ağın oluşmasına veya çözümü olan bir konuya iyi bir çözüm bulunamamasına neden olabilir. Bunun yanı sıra, bulunan çözümün en iyi çözüm olduğuna dair bir garanti yoktur. Yani yapay sinir ağları kabul edilebilir çözümler üretebilir, ama en iyi çözümü garanti etmez.

- Ağın davranışları açıklanamamaktadır. Bu sorun YSA'ların en önemli sorunudur. YSA bir probleme çözüm ürettiği zaman bunun neden ve nasıl olduğuna dair bir ipucu vermez. Bu durumda ağa olan güven azalmaktadır (Öztemel, 2012).

1.4.5. Yapay Sinir Ağlarının Kullanım Alanları

Yapay sinir ağlarının kullanılabileceği birçok alan vardır. Bunlardan bazıları aşağıda verilmiştir:

Veri madenciliği

Optik karakter tanıma ve çek okuma

Bankalardan kredi isteyen müracaatları değerlendirme

Ürünün pazardaki performansını tahmin etme

Kredi kartı hilelerini saptama

Zeki araçlar ve robotlar için optimum rota belirleme

Güvenlik sistemlerinde konuşma ve parmak izi tanıma

Robot hareket mekanizmalarının kontrol edilmesi

Mekanik parçaların ömürlerinin ve kırılmalarının tahmin edilmesi

Kalite kontrolü

İş çizelgeleme ve iş sıralaması

İletişim kanallarındaki trafik yoğunluğunu kontrol etme ve anahtarlama

Radar ve sonar sinyalleri sınıflandırma

Üretim planlama ve çizelgeleme

Kan hücreleri reaksiyonları ve kan analizlerini sınıflandırma

Kanser tanısı koyma

Çeşitli kronik hastalıkların tanısını koyduracak risk faktörlerini belirleme

Beyin modellenmesi çalışmaları

Hisse senedi fiyatlarının tahmini

Petrol ve gaz arama vb (Aydın, 2012).

Yapay sinir ağları çeşitli problemlerin çözümünde yaygın olarak kullanılmaktadır.

Geleneksel bilgisayarlar ve insanlar için oldukça zor olan problemleri çözmek için eğitilebilmektedirler (Sözen vd., 2004).

1.4.6. Yapay Sinir Ağlarının Yapısı

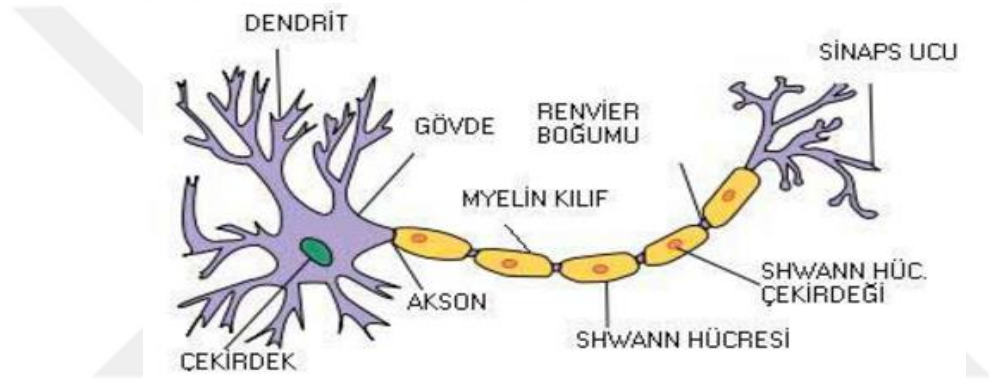
1.4.6.1. Biyolojik Sinir Hücresi

Biyolojik sinir ağları, beynimizde bulunan milyarlarca sinir hücresinin birleşiminden oluşmaktadır. Beynimizde 10^{10} adet sinir hücresi ve bunların 6×10^{13} ,ten fazla sayıda bağlantısının olduğu söylenmektedir (Şen, 2007).

Biyolojik sinir sistemi, bilgiyi alan, yorumlayan ve uygun kararlar üreten bir merkezdir. Sinir sisteminin temel elemanları nöron (neuron) adı verilen özel sinir

hücreleridir. Biyolojik bir sinir hücresi dentritler (dendrite), hücre gövdesi (soma), aksonlar (axon) ve sinapslardan (synapse) oluşmaktadır. Biyolojik sinir hücresi Şekil 1'de gösterilmektedir.

Sinir hücreleri birbirlerine dentritlerinden veya aksonlarından bağlanır. Bu bağlantı noktalarına sinaps denir. Sinapslar, bir diğer sinir hücresinin aksonundan aldıkları pozitif ya da negatif yönde elektrik akımının elektro-kimyasal bir yöntemle dentrite iletilmesini sağlarlar. Dentrit, aldığı elektrik akımını, somaya yani hücrenin gövdesine iletir. Soma, çekirdeği barındırır ve hücrenin yaşamasını sağlar. Hücrenin tüm dentritlerinden alınan elektrik sinyalleri burada toplanır (Bayır, 2006).



Şekil 1. Sinir hücresi (Alan, 2013).

Biyolojik sinir ağları performansları önemsiz sayılamayacak kadar yüksek ve karmaşık olayları işleyebilecek yeteneğe sahiptirler. Yapay sinir ağları, bu yeteneğin bilgisayarlara kazandırılmasını amaçlamaktadır (Bayır, 2006).

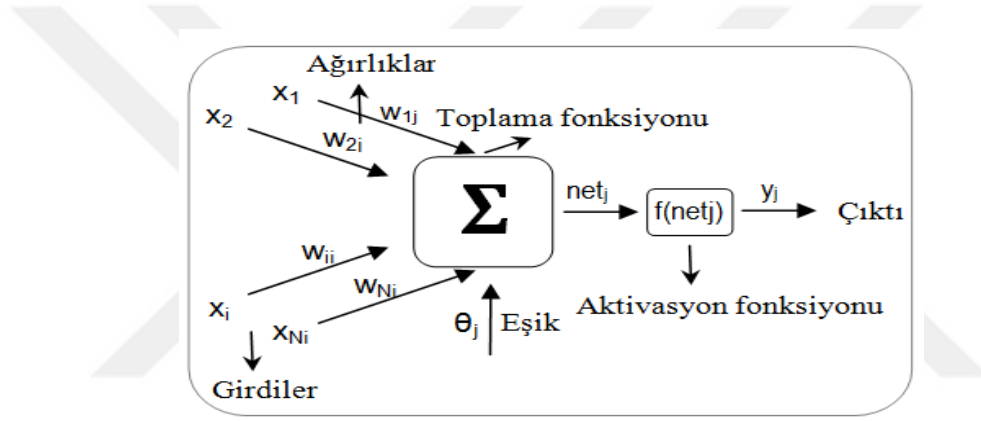
1.4.6.2. Yapay Sinir Hücresi

Yapay sinir ağlarının da biyolojik sinir ağları gibi sinir hücreleri vardır. Yapay sinir ağları, biyolojik sinir ağlarının modellenmesidir. Yapay sinir ağları, birbiriyle bağlantılı çok sayıda yapay sinir hücresinden (nöron) meydana gelmektedir ki bu nöronlar bilgileri alıp, çeşitli işlevlerle bir çıktı üretirler (Gürsoy, 2012). Yapay sinir ağları, insan beyninin çalışma şeklinden esinlenerek geliştirilmiş bir yöntemdir ve aralarında bazı benzerlikler bulunmaktadır. Bu benzerlikler Tablo 1'de verilmiştir.

Tablo 1. Biyolojik sinir ağı ve yapay sinir ağının karşılaştırılması (Fausett, 1994).

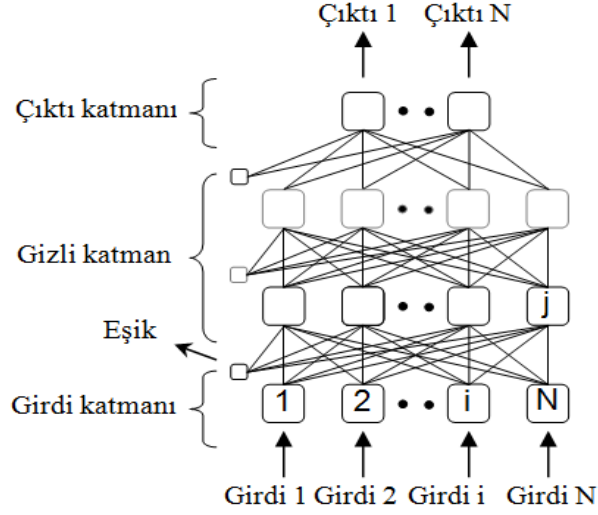
Biyolojik Sinir Sistemi	Yapay Sinir Ağları
Nöron	İşlemci eleman
Dentrit	Nöronlar arası bağlantılar
Hücre gövdesi	Aktivasyon fonksiyonu
Aksonlar	Yapay nöron çıkışı
Sinapslar	Ağırlıklar

Şekil 2’de görüldüğü gibi, yapay sinir ağlarının içinde olan sinir hücreleri verileri alıp çıktı üretmektedir.



Şekil 2. Basit bir yapay sinir hücresi (Özşahin, 2013).

Ağların birçoğu girdi, gizli ve çıktı katmanından oluşmaktadır. Bu özelliğe sahip olan ağa çok katmanlı ağ denilir. Tipik bir, çok katmanlı ağ Şekil 3’te verilmektedir. Bazı problemler için tek bir gizli katman yeterli olmaktadır ama bazı uygulamalarda gizli katman sayısı daha fazladır. Katman sayısı ve her bir gizli katmandaki nöron sayısı ise kullanıcı tarafından deneme yanılma yöntemiyle belirlenmektedir. İki nöron arasındaki her bir bağlantı bir ağırlığa sahiptir.



Şekil 3. Çok katmanlı algılayıcı (Özşahin, 2013).

1.4.7. Yapay Sinir Ağlarının Temel Elemanları

Bir yapay sinir hücresi genel olarak beş temel elemandan oluşmaktadır.

1. Girdiler
2. Ağırlıklar
3. Birleştirme fonksiyonu
4. Aktivasyon fonksiyonu
5. Çıktı

1.4.7.1. Girdiler

Girdiler, bir yapay sinir hücresinin çevreden aldığı bilgilerdir ve bu bilgiler için çıktı oluşmaktadır (Okutan, 2014).

1.4.7.2. Ağırlıklar

Ağırlıklar (w) bir yapay sinir hücresine gelen verinin o hücre üzerindeki etkisini gösterir. Ağırlıkların büyük yada küçük olması, önemli yada önemsiz olduğu anlamına gelmez. Bir ağırlığın değerinin sıfır olması o ağ için en önemli olay olabilir. Değerlerin artı

veya eksi olması etkisinin pozitif (arttırıcı) veya negatif (azaltıcı) olduğunu, sıfır olması ise herhangi bir etkinin olmadığını gösterir (Öztemel, 2006).

1.4.7.3. Birleştirme Fonksiyonu

Birleştirme fonksiyonu hücreye gelen net girdiyi hesaplayan bir fonksiyondur. En çok kullanılan Birleştirme fonksiyonu tipleri Tablo 2’de gösterilmiştir. Bu tabloda (G) girdileri, (A) ise ağırlıkları göstermektedir (Öztemel, 2012). Yapay sinir ağında her bir girdi, kendi ağırlık değerleri ile çarpıldıktan sonra, eşik değer ile toplanır. Bu işlemin adına, Birleştirme fonksiyonu denilmektedir. Sonraki adımda, Birleştirme fonksiyonundan elde edilen çıktı, aktivasyon fonksiyonuna gönderilerek net çıktı elde edilmektedir (Mete, 2008). En uygun Birleştirme fonksiyonu, deneme yanılma yöntemi ile bulunmaktadır. Bunlardan en çok kullanılanı, gelen her bir girdinin kendi ağırlıkları ile çarpıldıktan sonra toplanmasıdır. Böylece net girdiyi belirleyen toplam fonksiyon elde edilir (Mete, 2008).

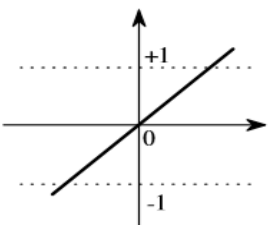
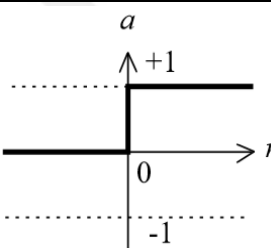
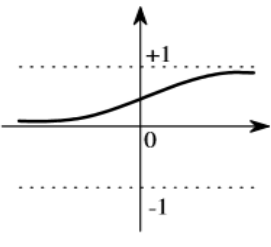
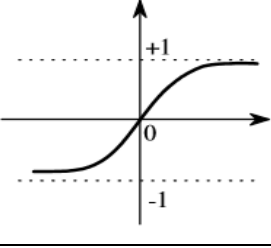
Tablo 2. Birleştirme fonksiyonu örnekleri

Net giriş	Açıklama
Toplam Net girdi= $\sum_i w_{ij} x_i$	Ağırlık değerleri girdiler ile çarpılır ve bulunan değerler birbirleriyle toplanarak Net girdi hesaplanır.
Çarpım Net girdi= $\prod_i G_i A_i$	Her bir girdi kendi ağırlık değeriyle çarpıldıktan sonra bulunan değerler birbirleriyle çarpılır ve net girdi elde edilir.
Net girdi= $Max(G_i A_i), i=1...N$	Girdiler kendi ağırlık değerleri ile çarpıldıktan sonra, en büyük olan değer ağırlık net girdisi olarak kabul edilir.
Net girdi= $Min(G_i A_i), i=1...N$	Girdiler kendi ağırlık değerleri ile çarpıldıktan sonra, en küçük olan değer ağırlık net girdisi olarak kabul edilir.
Çoğunluk Net girdi= $\sum_i sgn(G_i A_i)$	Her bir girdi kendi ağırlık değeriyle çarpıldıktan sonra pozitif ve negatif olanların sayısı bulunur. Büyük değer ağırlık net girdisi olarak kabul edilir.
Kümülatif toplam Net girdi= $Net(eski) + \sum_i (G_i A_i)$	Her bir girdi kendi ağırlık değeriyle çarpıldıktan sonra toplanır ve bir önceki bilgilere ilave edilerek ağırlık net girdisi elde edilir.

1.4.7.4. Aktivasyon Fonksiyonu

Birleştirme fonksiyonu, bütün girdileri alıp daha sonra üzerinde işlemler yaparak yapay sinir hücresinin net girdisini bulur. Birleştirme fonksiyonundan elde edilen net girdi sonraki basamakta aktivasyon fonksiyonuna gönderilir ve net girdi üzerinde işlemler yapılarak net çıktı hesaplanır. En sık kullanılan aktivasyon formülleri Tablo 3'te verilmektedir.

Tablo 3. Sık kullanılan aktivasyon fonksiyonları (Demuth vd., 2008).

Özdeşlik aktivasyon fonksiyonu	$f(x) = x$	
Eşik aktivasyon fonksiyonu	$f(x) = \begin{cases} 0, & x < 0 \\ 1, & x \geq 0 \end{cases}$	
Sigmoid aktivasyon fonksiyonu	$f(x) = \frac{1}{1 + e^{-x}}$	
Hiperbolik tanjant aktivasyon fonksiyonu	$f(x) = \frac{1 - e^{-x}}{1 + e^{-x}}$	

Birleştirme fonksiyonunda, her proses elemanı aynı Birleştirme fonksiyonuna sahip olabileceği gibi, farklı Birleştirme fonksiyonuna da sahip olabilmektedir. Bu durum tamamen tasarımcının öngörüsüne ve yaptığı denemelerin sonucuna bağlı olarak

gerçekleşmektedir. Sonuç olarak uygun fonksiyonu gösteren bir formül yoktur. Aktivasyon fonksiyonunun birçok çeşidi vardır ve genellikle doğrusal olmayan bir fonksiyondur. Aktivasyon işleminden geçen net girdi $[0,1]$ veya $[-1,1]$ aralığında değerler almaktadır (Hagan, 1996).

1.4.7.5. Çıktı

Her bir girdi kendi ağırlık değerleri ile çarpıldıktan sonra uygun bir Birleştirme fonksiyonunu kullanılarak net girdiye dönüşür. Daha sonra bu net girdi uygun bir aktivasyon fonksiyonuna aktarılarak net çıktı hesaplanır. Yapay sinir ağlarında çıktı, problemin çözümüdür. Üretilen çıktı dış dünyaya gönderilir (Alan, 2013).

1.4.8. Yapay Sinir Ağlarının Geleneksel Sistemlerden Farkları

Yapay sinir ağları, verilerin analiz edilmesi ve aralarındaki ilişkilerin ortaya çıkarılmasında geleneksel hesaplama tekniklerine göre farklı çözümler sunar. Geleneksel hesaplama yöntemleri ile yapay sinir ağları arasındaki bir takım farklılıklar Anderson ve McNeill'e göre Tablo 4'teki gibidir.

Tablo 4. Geleneksel hesaplama yöntemleri ile YSA'ların karşılaştırılması (Anderson ve McNeill, 1992).

Karakteristik	Geleneksel hesaplama (uzman sistemler dahil)	Yapay sinir ağları
İşlem sitali	Sıralı	Paralel
Fonksiyonlar	Kurallar, Kavramlar ve Hesaplama Yoluyla, Mantıksal (sol beyin)	Resimler, Görüntüler, Kontroller yoluyla, Geşalt (sağ beyin)
Öğrenme metodu	Kurallarla	Örneklerle
Uygulamalar	Muhasebe, Kelime İşlem, Matematik, Stok, Dijital iletişim	Sensor İşleme, Ses Tanıma, Desen Tanıma, Karakter Tanıma, Sınıflandırma

1.4.9. Yapay Sinir Ağlarının Tasarımı

Bir yapay sinir ağının başarılı olabilmesi için ağın iyi tasarlanması gerekmektedir. Bir sinir ağı modeli oluşturmak için nöronların bağlantı şekli (topoloji), işlemci elemanlarının kullandıkları Birleştirme ve aktivasyon fonksiyonları, öğrenme metodu, öğrenme kuralı ve algoritması belirlenmelidir. Kurulan modelin başarısı, modelin tasarımına bağlıdır. Modelin tasarımı ne kadar doğru oluşturulmuşsa, model o kadar başarılı demektir. Bunun için tasarımcıların, yapay sinir ağlarının tasarım sürecinde ağın yapısına dair, aşağıdaki kararları vermesi gerekmektedir (Bayır, 2006). Dikkat edilmesi gereken konulardan birisi, üzerinde araştırma yapılan konu ya da problemin YSA modeli ile çözümünün uygun olup olmadığının belirlenmesidir. Eğer uygun ise, yapay sinir ağlarıyla çözülmesi gereken problemin giriş ve çıkış katmanında kullanılacak parametrelerin belirtilmesi gerekmektedir. Kullanılacak yapay sinir ağı mimarisi ile YSA yapısının diğer unsurlarına tam olarak karar verildikten sonra, gizli katman sayısı ve her bir katman için nöron sayısı belirlenmelidir. Ağ hatasını minimum, öğrenme hızını maksimum yapan, optimum veya optimuma yakın katman ve işlem elemanı sayıları deneme/yanılma metodu ile belirlendikten sonra, YSA modeli tasarlanmış olup eğitim için hazır durumdadır (Bayır, 2006).

1.4.9.1. Normalizasyon

Yapay sinir ağındaki verilerin, ilk etapta hepsi bir aralıkta ve birbirleri ile benzer bir biçimde olması gerekmektedir. Tüm veriler değer olarak bir aralıkta ve birbirleri ile orantılı bir biçimde olmadığında, yani veriler arasındaki fark aşırı büyük ya da aşırı küçük ise, elde edilen net girdiler orantısız değerler halinde olacaktır. Bu nedenle, hesaplama hatalarından kaçınmak için, verilerin belirli bir aralıkta ölçeklendirilmesi gerekir. Genellikle ölçeklendirme için $[0 - 1]$ aralığı tercih edilir. Veri normalleştirme, eğitim süreci başlamadan uygulanır. En sık kullanılan normalleştirme formülleri aşağıdaki gibidir (Hamzaçebi, 2011).

a) [0,1] aralığına doğrusal dönüşüm:

$$x_n = \frac{x_0 - x_{min}}{x_{mak} - x_{min}} \quad (1)$$

b) [a,b] aralığına doğrusal dönüşüm:

$$x_n = (b - a) \frac{x_0 - x_{min}}{x_{mak} - x_{min}} + a \quad (2)$$

c) Basit normalizasyon:

$$x_n = \frac{x_0}{x_{mak}} \quad (3)$$

d) İstatistiksel normalizasyon:

$$x_n = \frac{x_0 - \bar{x}}{s} \quad (4)$$

x_n ve x_0 sırasıyla normalleştirilmiş ve orijinal veriyi temsil etmektedir. x_{min} , x_{mak} , x_n , \bar{x} ve s , sırasıyla minimum, maksimum, normalize edilmiş, ortalama ve standart sapmayı ifade etmektedir. Genellikle çıktı hedefleri ve girdilerin normalleştirilmesi birbirlerinden bağımsızdır. Zaman serileri problemlerinde, girdiler ve hedeflerin normalleştirilmesi birlikte yapılır. Girdilerin ve hedeflerin normalleştirilme aralığının seçimi, çıktı nöronlarının aktivasyon fonksiyonuna bağlıdır. Ağdan alınan sonuçların yorumlanması, çıktıların orijinal aralığa dönüştürülmesinden sonra olur (Hamzaçebi, 2011).

1.4.9.2. Yapay Sinir Ağı Topolojisinin Seçimi

Yapay sinir ağları ile problemin başarılı bir şekilde çözülmesi için YSA topolojisinin doğru bir biçimde belirlenmesi gerekmektedir. YSA topolojisinin seçimi problemin türüne bağlıdır. Ağ türlerini, kullanım alanları ve kullanım amacına göre aşağıdaki çizelgede gösterildiği gibi farklı kategorilerde incelemek mümkündür (Atasoy, 2010).

Tablo 5'te ağ kategorileri arasındaki farkları ve hangi topolojinin hangi amaçlarla kullanıldığını göstermektedir. Tablo tüm ağ topolojilerini değil, sadece çok kullanılan bazı ağ topolojilerini göstermektedir. Bazı ağlar, birden çok problem tipinin çözümünde kullanılmaktadır. İleri beslemeli geri yayılım ağları hemen hemen tüm problemlerin çözümünde kullanılmaktadır ve en çok kullanılan ağ topolojisidir (Anderson ve McNeill, 1992).

Tablo 5. Kullanım amaçlarına göre YSA topolojileri (Anderson ve McNeill, 1992).

Kullanım alanları	Ağ türleri
Tahmin-Öngörü	<ul style="list-style-type: none"> - Çok Katmanlı Ağlar - Yönlendirilmiş Rastsal Tarama (Directed Random Search) - Yüksek Dereceli Sinir Ağları - Geri Yayılım içinde SOM - Radyal Tabanlı Fonksiyon - Elman Ağı - Jordan Ağı
Desen (Örüntü) Sınıflandırma	<ul style="list-style-type: none"> - LVQ - ART - Olasılık Tabanlı Sinir Ağları - Tek veya Çok Katmanlı Algılayıcı - Boltzmann Makinesi - RBF
Veri İlişkilendirme	<ul style="list-style-type: none"> - Kohonen's SOM - Hopfield Ağları - Boltzmann Makinesi - Hamming Ağları - Çift Yönlü İlişkili Hafıza - Spatio-Temporal Desen Tanıma - ART
Kavramlaştırma / Kümeleme	- LVQ – SOM – ART
Veri Filtreleme	- Yeniden Dolaşım (Recirculation)
Optimizasyon	<ul style="list-style-type: none"> - Geri Yayılım - Olasılık Tabanlı Sinir Ağları - RBF
Kontrol	- Geri Yayılım – LVQ – RBF
Fonksiyon Yaklaşırma	- Geri Yayılım - RBF

1.4.9.3. Öğrenme Algoritmasının Seçimi

Yapay sinir ağının topolojisini belirledikten sonra diğer önemli adım öğrenme algoritmasının seçimidir. Ağın öğrenme algoritmasının seçimi, ağın topolojisine bağlıdır.

Yapay sinir ağlarında öğrenme algoritmaları, danışmanlı, danışmansız ve takviyeli öğrenme olarak üç gruba ayrılır.

1.4.9.4. Katman ve Nöron Sayısının Belirlenmesi

Yapay sinir ağlarında katman sayısı ve her katmandaki nöron sayısı problemin çözümüne bağlıdır. Katman sayısı ve her katmandaki nöron sayısı arttıkça, öğrenme seviyesi artarken, yakınsama süresi fazlalaşmaktadır. Diğer taraftan, eğer katman sayısı çok ise ağın öğrenme yerine ezberlemesine ve ağın karmaşıklığına sebep olur. Bununla birlikte katman ve katmanlardaki nöron sayısının çok az sayıda kullanılması, ağın öğrenememesine ve elde edilen çıktının hassasiyetinin azalmasına sebep olur. Katman ve nöron sayısının belirlenmesinde kesin bir kural yoktur. Genellikle deneme yanılma yöntemi ile birlikte ağların performansı değerlendirilerek uygun olan ağ seçilmektedir.

1.4.9.5. Yapay Sinir Ağlarının Eğitimi ve Testi

Başlangıçta rastgele atanan ağın ağırlık değerleri, ağa gösterilen örneklerle değiştirilmektedir ve ağırlık değerlerinin değiştirilmesi işlemine "ağın eğitilmesi" denilmektedir. Öğrenmenin amacı, ağa uygun olan ağırlık değerlerini belirleyerek, problem için doğru çıktı üretmektir.

Yapay sinir ağlarının eğitim süreci, belli kurallar çerçevesinde olmaktadır. Bu kurallara öğrenme kuralları adı verilmektedir. Ağırlıkların değiştirilmesi öğrenme kurallarına göre yapılır. YSA doğru ağırlık değerlerini bulduğu zaman, problemdeki örnekler için genellemeler yapabilme yeteneğine kavuşur ve ağın bu genelleştirme yapma özelliğine ağın öğrenmesi denilmektedir (Öztemel, 2012).

YSA'nın en önemli olan aşaması, eğitim aşamasıdır. Eğitim ve öğrenme farklı kavramlardır. Eğitime, ağın öğrenmesi için gerçekleşen adımlardır, öğrenme ise eğitim

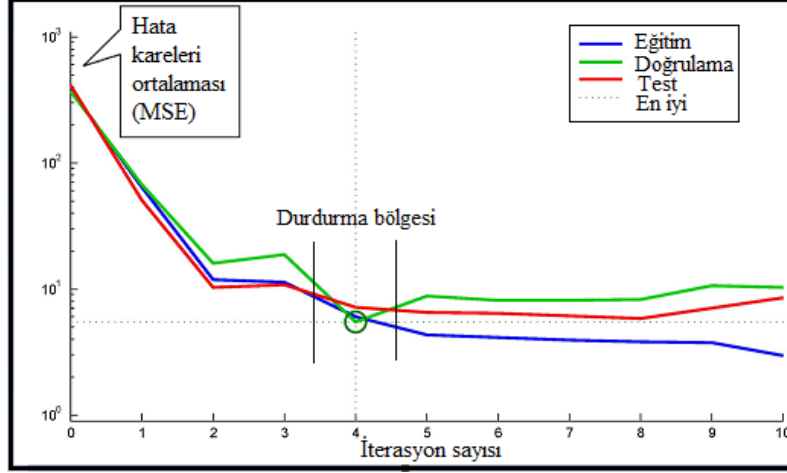
işleminin sonucudur. Eğitim yöntemi, ilgilenilen problemin özelliğine göre öğrenme kuralının YSA'ya nasıl uyarlanabileceğini belirtir (Özcan, 2007).

Yapay sinir ağını tasarlarlarken problemin verileri, eğitim ve test verisi olmak üzere, iki parçaya ayrılır. Bir yapay sinir ağına eğitimi tamamlandıktan sonra, bir ağı öğrenip öğrenmediğini sorgulamak için denemeler yapılması durumuna ağına test edilmesi denilmektedir. Ağına test edilmesi için, ağına görmediği örnekler kullanılır, ağına bu örnekler için çıktılar üretir, bu aşamada ağına ağırlık değerleri değiştirilmez. Elde edilen sonuçların doğruluk derecesi ne kadar yüksek ise eğitim performansı da o kadar iyi demektir (Baş, 2006).

Eğitim seti, ağına geliştirilmesi için; test seti ise modelin performansının değerlendirilmesi için kullanılır. Literatürde araştırmacılar bu ayrım hakkında, bir takım tavsiyelerde bulunmaktadır. Araştırmacılar, verilerin %90'ının eğitim veri seti ve %10'unun da test veri seti olarak kullanılmasını tavsiye etmektedirler. Bu oranları %80'i eğitim verisi, %20'si test verisi veya %70'i eğitim verisi %30'u test verisi olarak da ayırabilmek mümkündür (Zhang vd., 1998).

1.4.9.6. Eğitimin Sonlandırılması

Yapay sinir ağlarında, eğitim aşamasının sonlandırılacağı noktanın belirlenmesi, ağına genelleştirme yeteneğini etkileyebileceği gibi, ağına aşırı eğitilmesi durumunda da ezberleme probleminin neden olabilmektedir. Bu nedenle eğitim işleminin durdurulacağı noktanın belirlenmesi, ağına başarısını etkilemektedir. Yapay sinir ağı modellerinde, eğitimin sonlandırılması için üç yöntem vardır. Birinci yöntemde, ağına önceden belirlenen iterasyon sayısına ulaşması ile eğitim aşaması sonlandırılır. İkinci yöntemde, araştırmacı kabul edilebilir bir hata seviyesi belirleyerek eğitime işleme başlar. Ağına önceden belirlenen bu eğitim seviyesine ulaştığı zaman, eğitim durdurulur. Son yöntem ise, çapraz geçerlilik olarak da bilinen onaylama seti için, hata oranının yükselmeye başladığı anda, eğitimin durdurulmasıdır. Bu yöntemde, ağına eğitimi için kullanılacak olan örnek set üç kümeye ayrılır. Ağına eğitimi aşamasında, ağırlık değerleri belirlenirken, geçerlilik setinin hata oranı dikkate alınır. Şekil 4'te görüldüğü gibi, geçerlilik setinin hata oranı, eğitim setinin hata oranını geçtiği noktada eğitim durdurulur. Bu noktada ağırlık değerleri, en uygun ağırlık değerleri olarak alınır (Akdağ, 2010).



Şekil 4. Eğitimin durdurulma bölgesi (Esfahani vd., 2015).

1.4.9.7. Performans Fonksiyonunun Belirlenmesi

Ağ performans fonksiyonu öğrenme performansını ölçen bir fonksiyondur. Bu ölçüt sayesinde istenilen çıktı değerleri ile ağın ürettiği değerler arasındaki farklar hesaplandıktan sonra, sıra ağın ne kadar doğru tahmin yaptığında, yani ağın performansının ve öğrenme yeteneğinin başarı seviyesinin belirlenmesindedir (Bahadır, 2013). En çok kullanılan performans ölçütleri (5), (6) ve (7) nolu Formüllerde gösterilmiştir (Özşahin, 2013).

$$\text{Hata Kareleri Ortalaması (MSE)} = \frac{1}{N} \sum_{i=1}^N (t_i - td_i)^2 \quad (5)$$

$$\text{Ortalama Mutlak Yüzde Hata (MAPE)} = \frac{1}{N} \left(\sum_{i=1}^N \left[\left| \frac{t_i - td_i}{t_i} \right| \right] \right) \times 100 \quad (6)$$

$$\text{Karesel Ortalama Hata Karekökü (RMSE)} = \sqrt{\frac{1}{N} \sum_{i=1}^N (t_i - td_i)^2} \quad (7)$$

Yukarıdaki denklemlerde t_i ağın ürettiği çıktı, td_i gerçek çıktıları ve N toplam veri sayısını göstermektedir.

1.4.9.8. Diğer Etkenler

Yapay sinir ağı modeli geliştirilirken, önemli bir diğer konu da ağ parametrelerinin belirlenmesidir. Bu parametreler, başlangıç ağırlıklarının atanması, momentum ve öğrenme katsayılarının belirlenmesi, Birleştirme ve aktivasyon fonksiyonlarının seçilmesidir. Uygun ağ parametrelerinin belirlenmesi, ağ başarısını önemli ölçüde etkilemektedir. Ağ mimarisinde olduğu gibi, bu parametrelerin belirlenmesinde de kesin formüller bulunmamaktadır. Deneme yanılma yöntemi ile uygun parametre değerleri belirlenmeye çalışılmaktadır. Bu parametreler belirlenmeye çalışılırken dikkat edilmesi gereken noktalar aşağıda özetlenmiştir (Hamzaçebi, 2011).

1.4.9.8.1. Öğrenme Katsayısı

Öğrenme katsayısı, adım büyüklüğünü tayin etmektedir. Öğrenme oranı, ağırlıkların bir sonraki düzeltmede ne kadar değişmesi gerektiğini belirlemektedir. Öğrenme oranı, genellikle 0 ile 1 arasında bir değerdir. Öğrenme oranının büyük değerleri, değişim miktarını artırırken, küçük bir değer seçilmesi ise öğrenme süresinin uzamasına ve ağın yerel çözümlere takılmasına neden olmaktadır. Yerel çözüm şu şekilde açıklanabilmektedir: Bir problemin çözümü için en az hatayı veren ağırlık vektörünü pratikte her zaman yakalamak mümkün olmayabilir. Bu çözüm, ağın sahip olabileceği en iyi çözümdür (Mutlak Minimum). Fakat bu çözüme nasıl ulaşılacağı tam olarak bilinmemektedir. Ağ, eğitim sırasında bu çözüme ulaşmaya çalışmaktadır. Ancak bazen ağ farklı bir çözüme takılabilmekte ve performansı daha fazla iyileştirmek mümkün olmamaktadır (Mehrotra vd., 1997).

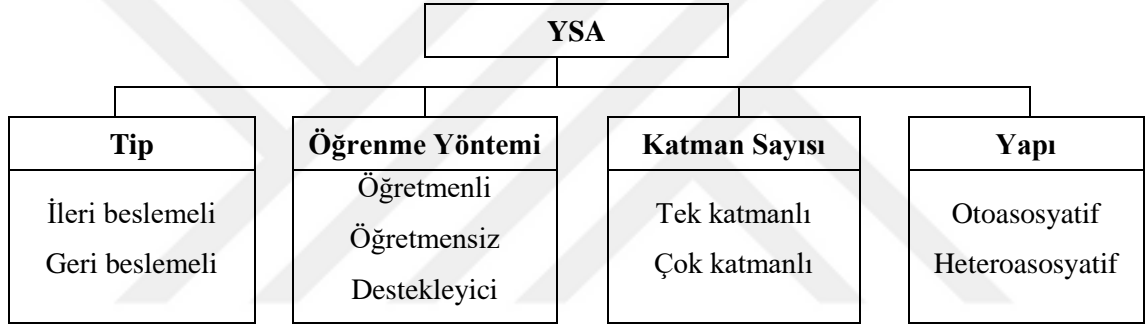
1.4.9.8.2. Momentum Katsayısı

Momentum katsayısı, her bir döngü sonunda gerçekleşen parametre değişiminin, bir sonraki parametreye etki oranını belirler. Böylece, ağın eğitimi sırasında ağırlık değişim değerinin, bir sonraki değişime hangi oranda yansıtacağı belirlenir (Altınışık, 2012). Momentum katsayısı, ağın daha hızlı toparlanmasına yardım eden bir faktördür. 0 ile 1 arasında değerler almaktadır. Momentum katsayısı 0 değerini aldığı zaman, ağırlık

değişiminde geçmiş değişim miktarının dikkate alınmaması, 1 değerini aldığı zaman ise ağırlık değişiminin daha çok geçmiş değişime bağlı olması anlamına gelir (Hamzaçebi, 2011).

1.4.10. Yapay Sinir Ağlarının Sınıflandırılması

Yapay sinir ağlarını, farklı ölçütleri göz önüne alarak sınıflandırmak mümkündür. Genel olarak YSA, tiplerine, öğrenme yöntemlerine, katman sayılarına ve yapılarına göre sınıflara ayrılmaktadır (Hamzaçebi, 2011). YSA'ların sınıflandırılması Şekil 5'te verilmiştir.




Şekil 5. YSA'ların sınıflandırılması

1.4.10.1. Türlerine Göre Yapay Sinir Ağları

Yapay sinir ağları nöronlar arasındaki bağlantıların yönlerine göre değerlendirilmektedir. Yapay sinir ağlarını yapılarına göre ileri beslemeli ve geri beslemeli ağlar olarak sınıflandırmak mümkündür. Nöronlar arasındaki bağlantıların yapısı, ağın yapısını da belirler. Bağlantıların nasıl olacağı, öğrenme algoritması tarafından belirlenir (Ataseven, 2007).


a) İleri Beslemeli Ağlar: Yapay sinir ağlarında, nöronlar katman şeklinde düzenlenir ve giriş katmanına giren veriler kendi ağırlık değerleriyle çarpıldıktan sonra bir sonraki katmana gönderilir. Başka bir deyişle ağ, dış ortamlardan aldığı bilgiyi, gizli katman ve çıktı katmanında işleyerek, ağın çıktısını belirler (Çuhadar ve Kayacan, 2005). İleri beslemeli yapay sinir ağlarında sinyaller sadece tek bir yönde, girdi katmanından çıktı katmanına doğru yönelir. İleri beslemeli ağlarda nöronlar yalnızca bir sonraki katmanda

bulunan nöronlarla bağlantıya sahiptir. İleri beslemeli ağ modellerinde, ağın çıktısı tamamen ağa giren girdilere bağlıdır (Tolon ve Tosunoğlu, 2008). Şekil 6'da ileri beslemeli YSA yapısı gösterilmektedir.



Şekil 6. İleri beslemeli ağ yapısı (Özşahin, 2013).

b) Geri Beslemeli Ağlar: Veri akışının sadece ileriye doğru değil, geriye doğru da olduğu bir ağ yapısıdır. Bu ağ yapısında, ağ çıktısı aynı zamanda girdi olarak da kullanılabilir. İleri beslemeli ağlarda, geri beslemeli ağlarda olduğu gibi nöronlar katmanlarda bulunur. Ancak katmanlar arası bağlantılar tek yönlü değil çift yönlüdür. Bir geri beslemeli ağ, çıktı ve ara katman çıktılarının girdi birimlerine veya önceki ara katmanlarla geri beslendiği bir ağ yapısıdır. Böylece girdiler hem ileri yönde hem de geri yönde aktarılmış olur. Şekil 7'de geri beslemeli YSA yapısı gösterilmektedir (Kaya vd., 2005).



Şekil 7. Geri beslemeli ağ yapısı (Bahadır, 2013).

1.4.10.2. Öğrenme Yöntemine Göre Yapay Sinir Ağları

Yapay sinir ağlarında bir ağın ağırlıklarının probleme göre değiştirilmesi ile öğrenme sağlanır. Öğrenme yöntemi genel olarak üç öğrenme metodundan ibarettir. Bu öğrenme yaklaşımları danışmanlı, danışmansız ve takviyeli olmak üzere üç farklı gruba ayrılır. Bu gruplar aşağıda açıklanmıştır.

a) Danışmanlı öğrenme: Yapay sinir ağlarında en çok kullanılan öğrenme yöntemlerinden olan danışmanlı öğrenmede, ağa verilen örneklere karşılık ağ, bir çıktı sunmaktadır. Daha sonra ağa örnek olarak sunulan çıktı ile ağın ürettiği çıktı arasında bir karşılaştırma yapılır. İki çıktı arasındaki fark hata olarak alınır. Başlangıçta genellikle rastgele verilen ağırlıklar, ağ hatayı minimum edene kadar her döngüde değiştirilir. Genelleştirilmiş delta kuralı ve geri besleme algoritması, danışmanlı öğrenme metoduna örnek olarak verilebilir (Anderson ve McNeill, 1992).

b) Danışmansız öğrenme: Sistemin öğrenmesi için herhangi bir öğretmen yoktur. Bu sebeple bu yönteme kendi kendine öğrenme de denilmektedir. Ağ, kendine sunulan örnek girdileri alır ve belli bir kritere göre sınıflandırır. Bu kriterler önceden bilinmeyebilir. Ağ, kendi öğrenme kriterlerini kendisi oluşturmaktadır. Örnekteki parametreler arasındaki ilişkileri sistemin kendi kendine öğrenmesi beklenir. Danışmanlı öğrenmeye göre çok daha hızlıdır ve matematiksel algoritmaları daha basittir (Deveci, 2012). Danışmansız öğrenmede sistemin gerçek çıktı hakkında bilgisi yoktur. Girdilere göre kendi kendisini örnekler. Bu yöntemde ağırlıklar girdi bilgilerine göre değerlerini ayarlarlar (Elmas, 2003).

c) Destekleyici öğrenme: Bu öğrenme kuralı, danışmanlı öğrenmeye yakın bir yöntemdir. Destekleyici öğrenme, sadece ağın ürettiği çıktının doğru veya yanlış olduğunu söyleyen bir yöntemdir. Bir destekleyici işaret gönderilmesiyle gerçekleşir. Her döngüde ağın sonucu için, sonucun ne kadar doğru veya yanlış olduğuna dair bir bilgi verilmektedir. Ağ bu bilgilere göre kendini tekrar düzenler (Deveci, 2012).

1.4.10.3. Katman Sayılarına Göre Yapay Sinir Ağları

Yapay sinir ağları basit bir yapıya sahiptir. YSA'da nöronlar katmanlarda toplanır. Toplam üç çeşit katman bulunur: girdi katmanı, çıktı katmanı ve gizli katman. Başka bir deyişle dış dünyadan girdileri alan nöronların bulunduğu katman girdi katmanı, ağın oluşturduğu çıktıyı dış dünyaya ileten katman çıkış katmanı, giriş ve çıkış katmanı arasında

bulunan katman ise gizli katman olarak adlandırılmaktadır. Karmaşık problemlerin çözülmesi için ağların gizli katmana sahip olması gerekmektedir. Ancak gizli katmanlar fazla olursa ağda genelleşme sorunu oluşabilmektedir. Bu sebeple ağdaki gizli katman sayısı, en iyi çıktıyı verecek şekilde seçilmelidir (Kaya, 2013).

Yapay sinir ağı, eğer tek bir katmandan oluşuyor ise tek katmanlı YSA, birden fazla katmandan oluşuyor ise çok katmanlı YSA olarak adlandırılmaktadır (Hamzaçebi, 2011).

Tek Katmanlı Yapay Sinir Ağı: Tek katmanlı yapay sinir ağı en basit ağ yapısıdır. Bir giriş katmanı ve bir çıkış katmanı vardır (Ergin, 2012).

Çok Katmanlı Yapay Sinir Ağı: Çok katmanlı ağların çalışma prensibi, tek katmanlı ağlarla aynı şekildedir. Farklı olarak çok katmanlı yapay sinir ağlarında girdi ve çıktı katmanları arasında gizli katmanların bulunmasıdır (Güngör, 2007).

1.4.10.4. Yapısına Göre Yapay Sinir Ağları

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 (Hamzaçebi, 2011).

1.4.11. Çok Katmanlı Algılayıcı

Çok katmanlı algılayıcılar (ÇKA) mühendislik problemlerinin hemen hepsi için çözüm üretilebilmektedir. Bu yüzden yapay sinir ağları ile birlikte yeniden akademik çalışmalar hızlanmıştır. Basit algılayıcılarda girdi ve çıktılar arasında doğrusal ilişki olmadığı zaman çözüme ulaşmanın mümkün olmadığı görülmüştür.

Çok katmanlı algılayıcılar, öğrenme algoritması olarak genelde türeve dayalı geri yayılım (backpropagation) veya hata yayma algoritmaları olarak kullanılmaktadır. Bu sebeple ÇKA'ya geri yayılım ağı da denilmektedir. ÇKA, ADALINE modelinde de kullanılan delta öğrenme kuralının gelişmiş halini kullanmaktadır (Kröse ve Smagt, 1996).

Delta kuralı, en küçük kareler yöntemine dayalı bir öğrenme kuralıdır. ÇKA, öğretmenli öğrenme metodunu kullanmaktadır. Yapay sinir ağının öğrenmesi için verilerin

bir kısmının eğitim kümesi adı verilen bir sete ayrılması gerekmektedir. Bu set içinde her örnek için hem girdiler, hem de o girdilere karşılık gelen, ağırlık üretmesi gereken çıktılar belirlenmektedir. Öğrenme sırasında her örnek için ağırlık ürettiği çıktı değeri ile gerçek çıktı değeri arasında bir karşılaştırma yapılır ve hata değeri ağırlık tekrar geri besleme şeklinde verilir. Örnek setindeki hata kareleri toplamını (HKT) azaltmak için işlemci elemanlar arasındaki bağlantı ağırlıkları değiştirilmektedir. Bir yapay sinir ağırlığının geri yayılım yoluyla eğitilmesi; ileriye doğru hesaplama ve geriye doğru hesaplama olmak üzere iki aşamadan oluşmaktadır (Kröse ve Smagt, 1996).

Algoritmada kullanılan simgeler Tablo 6’da tanımlanmıştır (Hamzaçebi, 2011).

Tablo 6. Geri yayılım için tanımlamalar

Simgeler	Anlamları
X	Girdi vektörü
T	Çıktı hedef vektörü
S	Eğitim kümesindeki girdi-çıkıtı çifti sayısı ($s= 1,2,\dots,S$)
δ_k	O_k çıkıtı nöronunda oluşan hata için v_{jk} ağırlıkları için düzeltme payı
δ_j	w_{ij} ağırlıkları için düzeltme payı
η	Öğrenme oranı
λ	Momentum katsayısı
X_i	i. girdi nöronu: Bir girdi nöronu için girdi değeri ile çıkıtı değeri aynıdır (x_i)
W_{oj}	j. gizli nöron için eşik değeri ağırlığı
Z_j	j. gizli nöron: Bir gizli nöronun net girdisi ($Z_{netgirdij}$) ve çıkıtısı (Z_j) aşağıdaki gibi hesaplanır. $Z_{netgirdij} = w_{0j} + \sum_i w_{ij}x_i$ $Z_j = f(Z_{netgirdij})$
V_{ok}	k. çıkıtı nöronu için eşik değeri ağırlığı
O_k	k. çıkıtı nöronu: Bir çıkıtı nöronun net girdisi ($O_{netgirdik}$) ve çıkıtı (O_k) aşağıdaki gibi hesaplanır. $O_{netgirdik} = v_{0k} + \sum_j v_{jk}Z_j$ $O_k = f(O_{netgirdik})$

GYA algoritmasının adımları:

Aşama 1: Başlangıç ağırlıkları rassal olarak atanır. Öğrenme parametreleri belirlenir. Durdurma kriteri belirlenir.

Aşama 2: Durdurma kriteri sağlanıncaya kadar aşama 3-10 tekrarlanır.

Aşama 3: Eğitim kümesindeki her bir girdi-çıkı çifti için aşama 4-9 tekrarlanır.

Aşama 4: Girdi katmandaki nöronlar dışarıdan girdi değerlerini alır (x_i ; $i = 1, 2, \dots, n$) ve gizli katman nöronlarına gönderir.

Aşama 5: Gizli katman nöronları gelen net girdiyi aktivasyon fonksiyonundan geçirerek kendi çıktısını üretir ve çıkı katmanı nöronlarına gönderir. Formül (8) ve (9)'da verildiği gibi hesaplanır.

$$Z_{j_{netgirdi}} = w_{0j} + \sum_i w_{ij} x_i \quad (8)$$

$$Z_j = f(Z_{j_{netgirdi}}) \quad (9)$$

Aşama 6: Çıkı katmanı nöronları gelen net girdiyi aktivasyon fonksiyonundan geçirerek kendi çıktısını üretir. Formül (10) ve (11)'de verildiği gibi hesaplanır.

$$O_{k_{netgirdi}} = v_{0k} + \sum_j v_{jk} Z_j \quad (10)$$

$$O_k = f(O_{k_{netgirdi}}) \quad (11)$$

Aşama 7: Her bir çıkı nöronu için hata bilgi değeri Formül (12)'deki gibi hesaplanır.

$$\delta_k^{çikı} = (t_k - o_k) f'(o_{k_{netgirdi}}) \quad (12)$$

Böylece gizli katmanı çıkı katmanına bağlayan bağlantıların ve eşik teriminin ağırlıklarındaki değışim miktarı Formül (13) ve (14)'teki gibi hesaplanır.

$$\Delta v_{jk}^{yeni} = \eta \delta_k^{ciktı} z_j + \lambda \Delta v_{jk}^{eski} \quad (13)$$

$$\Delta v_{0k}^{yeni} = \eta \delta_k^{ciktı} + \lambda \Delta v_{0k}^{eski} \quad (14)$$

Aşama 8: Her bir gizli katman nöronu için net hata girdisi Formül (15)'teki gibi hesaplanır.

$$\delta_{jnet}^{gizli} = \sum_{k=1}^p \delta_k^{ciktı} v_{jk} \quad (15)$$

Net hata girdisi yardımı ile her gizli nöron için hata bilgi değeri Formül (16)'da elde edilir.

$$\delta_j^{gizli} = \delta_{jnet}^{gizli} f'(z_{jnetgirdi}) \quad (16)$$

Böylece girdi katmanını gizli katmana bağlayan bağlantıların ve eşik teriminin ağırlıklarındaki değişim miktarı Formül (17) ve (18)'de verildiği gibi hesaplanır.

$$\Delta w_{ij}^{yeni} = \eta \delta_j^{gizli} x_i + \lambda \Delta w_{ij}^{eski} \quad (17)$$

$$\Delta w_{0j}^{yeni} = \eta \delta_j^{gizli} + \lambda \Delta w_{0j}^{eski} \quad (18)$$

Aşama 9: Ağırlıkların değiştirilmesi:

Her bir çıktı nöronu için ağırlıklar Formül (19)'daki gibi değiştirilir.

$$v_{jk}^{yeni} = v_{jk}^{eski} + \Delta v_{jk}^{yeni} \quad k = 1, 2, \dots, p \quad j = 0, 1, \dots, m \quad (19)$$

Benzer şekilde her bir gizli katman nöronu için ağırlıklar Formül (20)'deki gibi değiştirilir.

$$w_{ij}^{yeni} = w_{ij}^{eski} + \Delta w_{ij}^{yeni} \quad i = 0, 1, \dots, n \quad (20)$$

Aşama 10: Durdurma kriterinin sağlanıp sağlanmadığı kontrol edilir (Hamzaçebi, 2011).

1.5. Regresyon Analizi

Regresyon analizinde kullanılan değişkenler, biri bağımsız (açıklayıcı) değişken, diğeri ise bağımlı (açıklanan) değişken olmak üzere ikiye ayrılmaktadır. Bağımsız değişken, bağımlı değişken üzerinde etkisi olan bir değişken olup X ile ifade edilmektedir. Bağımlı değişken ise değeri bağımsız değişkenin etkisiyle değişen değişkendir ve Y ile ifade edilmektedir.

Bağımlı ve bağımsız değişkenler arasında birlikte bir değişim olup olmadığını matematiksel olarak ortaya çıkaran tekniğe regresyon; bağımsız değişkenin belirli bir birim değişmesi durumunda, bağımlı değişkenin ortalama olarak nasıl bir değişim gösterdiğini yani, nedensellik bağıntılarını inceleyen çözümlmeye ise regresyon analizi adı verilir (Orhunbilge, 1996).

1.5.1. Regresyon Modelleri

Regresyon analizi, iki veya daha fazla değişken arasındaki sebep-sonuç ilişkisini belirlemektedir ve bu ilişkiyi kullanarak o konuyla ilgili bilinmeyen geleceğin tahminini yapabildiği bir tahmin yöntemidir. Bu yöntemde iki veya daha fazla değişken arasındaki ilişkiyi açıklamak için matematiksel bir model kullanılır ve bu model regresyon modeli olarak adlandırılır (Kaysal vd., 2015).

İki çeşit regresyon modeli bulunmaktadır. Bunlar tek bağımsız değişkeni olan basit regresyon ve birden fazla bağımsız değişkeni olan çok değişkenli regresyon analizidir. Değişkenler arasında doğrusal ilişki olabileceği gibi, doğrusal olmayan bir ilişki de olabilir. Bu nedenle, serpilme grafiği yapılmadan (ilişki yok/doğrusal ilişki var/doğrusal olmayan ilişki var) ve değişkenler arasında korelasyon varlığına rastlanmadan regresyon analizine karar verilmemesi gerekir (Hamzaoğlu, 2013). Regresyon analizi; tıp, biyoloji,

mühendislik, ziraat, ekonomi, işletme, finans, davranış bilimleri vb. gibi çok farklı bilim dallarında sıkça kullanılmaktadır (Bölükbaş, 2010).

1.5.2. Basit Doğrusal Regresyon

Basit doğrusal regresyon analizi, bağımlı değişken ile bağımsız değişkenler arasındaki ilişkinin ve bağımsız değişkenlerin bağımlı değişken üzerindeki etkilerinin belirlenmesinde kullanılır. Basit doğrusal regresyon analizi, değişkenler arasındaki ilişkinin yapısı ile ilgilenmektedir. Basit doğrusal regresyon analizinde bir bağımsız değişken bulunur ve Formül (21)'deki gibi ifade edilmektedir (Gamgam ve Ünver, 2008).

$$Y = \beta_0 + \beta_1 X + \varepsilon \quad (21)$$

Regresyon modelinde yer alan simgelerin tanımı aşağıda belirtilmiştir.

Y: Bağımlı değişken simgesidir ve belli bir hataya sahip olduğu varsayılmaktadır.

X: Bağımsız değişken simgesidir ve hatasız ölçüldüğü varsayılmaktadır.

β_0 : Sabit bir değerdir ve X sifıra eşit olduğu zaman bağımlı değişkenin aldığı değerdir. Doğrunun y-eksenini kestiği noktadır.

β_1 : Bu değişken regresyonun katsayısıdır. X'te meydana gelen bir birimlik bir değişimin Y de meydana getirdiği değişim miktarını ifade eder. Kısaca eğim katsayısı olarak da adlandırılır.

ε : Hata teriminin göstergesidir.

Regresyon katsayılarının basit bir şekilde tahmin edilmesi için, en küçük kareler yöntemi kullanılmaktadır. En küçük kareler yöntemini Alman Matematikçi Carl Friedrich Gauss ortaya atmıştır. Bu yöntem Formül (22), (23) ve (24)'te anlatılmıştır.

$$Y_i = \beta_0 + \beta_1 X + e = \hat{Y} + \hat{e} \quad (22)$$

$$\hat{e} = Y_i - \hat{Y} \quad (23)$$

$$\sum \hat{e}^2 = \sum (Y_i - \hat{Y})^2 \quad (24)$$

En küçük kareler Yöntemi $\sum e^2$ 'yi minimum yapan β_0 ve β_1 değerlerinin bulunmasıdır.

β_0 ve β_1 katsayılarının elde edilmesi için En küçük kareler yöntemi Formül (25) ve (26)'da verilmiştir.

$$\beta_1 = \frac{n(\sum xy) - (\sum x)(\sum y)}{n(\sum x^2) - (\sum x)^2} \quad (25)$$

$$\beta_0 = \frac{(\sum y)(\sum x^2) - (\sum x)(\sum xy)}{n(\sum x^2) - (\sum x)^2} \quad (26)$$

Eğer önce β_1 bulunursa, daha sonra $\beta_0 = \bar{y} - \beta_1\bar{x}$ elde edilir ve böylece regresyonun katsayıları belirlenir. Bununla birlikte regresyon denklemi elde edilir.

Basit doğrusal regresyon modelinin ve hata terimlerinin varsayımları aşağıdaki gibidir.

Basit doğrusal regresyon modelinin varsayımları:

1. Bağımsız değişkenin değerleri sabit kabul edilir. Bağımlı değişkenin değerleri ise rastgeledir.
2. Değişkenler hatasız ölçülmüştür.
3. Her X_i değeri için; Y_i değerleri birbirinden bağımsızdır, Y_i gözlemlerinin dağılımı normaldir.
4. Bağımlı ve bağımsız değişkenler arasındaki ilişki doğrusaldır.
5. Gözlem sayısı değişken sayısından çok olmalıdır.

Hata terimi (e_i) varsayımları:

1. Hataların beklenen değeri sıfırdır. $E(e) = 0$
2. e 'lerin olasılık dağılımının varyansı sabittir. $V(e_i) = \sigma^2$
3. Hata değerleri birbirinden bağımsızdır.
4. Hataların dağılımı normaldir.
5. Hatalar ile bağımlı değişken arasında ilişki yoktur. $Cov(e, Y) = 0$
6. Hatalar ile bağımsız değişkenler birbirinden bağımsızdır. $Cov(e, X_i) = 0$.

Bu varsayımlar çoklu regresyon için de gereklidir (Kutlar, 2007; Hamzaoğlu, 2013).

1.5.3. Çoklu Doğrusal Regresyon

Çoklu doğrusal regresyon (ÇDR) yaygın olarak kullanılan istatistiksel yöntemlerden birisidir. Varsayımlar sağlandığında oldukça güçlü bir araçtır.

Y bağımlı değişkeni ve X bağımsız değişkenleri arasında neden-sonuç ilişkisini matematiksel bir modelle ortaya koyan yönteme çoklu regresyon analizi denilmektedir. Basit doğrusal regresyonda bir tek değişken vardır ancak bazı problemlerde, bağımlı değişkeni birden fazla bağımsız değişken etkilemektedir. Çoklu regresyon birden fazla bağımsız değişkene sahiptir. İstatistikte çoklu doğrusal regresyon modeli matematiksel olarak Formül (27)'deki gibi ifade edilmektedir (Geçkil, 2014).

$$Y = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_n X_n + \varepsilon \quad (27)$$

Burada:

X_i, \dots, X_n : Bağımsız değişkenlerin i. gözlem değerini göstermektedir.

β_0 : Regresyon doğrusunun y eksenini kestiği noktanın orijine olan uzaklığını göstermektedir.

β_1, \dots, β_n : Regresyon katsayısı olup bağımsız değişkendeki bir birimlik değişime karşılık bağımlı değişkende kendi birimi cinsinden meydana gelen ortalama değişim miktarlarını göstermektedir.

n: bağımsız değişken sayısı

ε : hata değeri

Bütün tahmin değerlerini hesaplayacak eşitlik Formül (28)'deki gibidir.

$$\hat{Y} = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_n X_n \quad (28)$$

Burada \hat{Y} tahmin edilen Y değerleri vektörünü ifade etmektedir. Formül (28)'deki değişkenlerin matris şeklinde gösterimi Formül (29)'deki gibidir.

$$Y = \begin{bmatrix} Y_1 \\ Y_2 \\ \dots \\ Y_n \end{bmatrix} \quad \beta = \begin{bmatrix} \beta_1 \\ \beta_2 \\ \dots \\ \beta_n \end{bmatrix} \quad X = \begin{bmatrix} 1 & X_1 \\ 1 & X_2 \\ \dots & \dots \\ 1 & X_n \end{bmatrix} \quad \varepsilon = \begin{bmatrix} \varepsilon_1 \\ \varepsilon_2 \\ \dots \\ \varepsilon_n \end{bmatrix} \quad (29)$$

Formül (29)'daki parametre tahmini değerleri ($\hat{\beta}$) Formül (30) ile hesaplanabilir (Yıldırım, 2010).

$$\hat{\beta} = (X'X)^{-1}X'Y \quad (30)$$

Regresyon modelleri doğrusal ya da doğrusal olmayan modeller olarak sınıflandırılabilir. Ancak doğrusal olmayan modeller çeşitli yöntemlerle doğrusal modellere dönüştürülebilir.

1.6. Temel Bileşen Analizi

Temel bileşen analizi (TBA), çok sayıda birbiri ile ilişkili değişkenler içeren, veri setinin boyutunu azaltmak için kullanılan bir tekniktir (Çilli, 2007).

TBA, verileri daha az sayıda değişkene indirgemek için en iyi dönüşümü bulmaya çalışmaktadır. Dönüşüm sonrasında elde edilen değişkenler ilk değişkenlerin temel bileşenleri olarak adlandırılır. İlk temel bileşen varyans değeri en büyük olandır ve diğer temel bileşenler varyans değerleri azalacak şekilde sıralanır. Gürültüye karşı düşük hassasiyet, bellek ve kapasite ihtiyaçlarının azalması, az boyutlu uzaylarda daha etkin çalışması TBA'nın temel avantajları arasında sıralanabilir (Sütçüler, 2006).

1.6.1. Temel Bileşen Analizinin Aşamaları

Parametrelerin ortalama sıfır (zero mean) olduğu farz edilerek bütün parametreler bir matriste birleştirilir. Temel bileşen analizinin aşamaları aşağıda verilmektedir.

Formül (31)'de görüldüğü gibi n adet gözlem ve m adet değişkenden oluşan $X_{n \times m}$ matrisi verilmiştir (Russell, 2011).

$$X_{n \times m} = \begin{bmatrix} x_{11} & x_{12} & \dots & x_{1m} \\ x_{21} & x_{22} & \dots & x_{2m} \\ \dots & \dots & \ddots & \dots \\ x_{n1} & x_{n2} & \dots & x_{nm} \end{bmatrix} \quad (31)$$

Sonraki aşamada değişkenlerin değerlerini içeren (X) matrisine ait kovaryans matrisi hesaplanır. Kovaryans matrisi Formül (32)'de verilmiştir.

$$C_{n \times m} = \begin{bmatrix} \sigma_{11} & \sigma_{12} & \dots & \sigma_{1m} \\ \sigma_{21} & \sigma_{22} & \dots & \sigma_{2m} \\ \dots & \dots & \ddots & \dots \\ \sigma_{n1} & \sigma_{n2} & \dots & \sigma_{nm} \end{bmatrix} \quad (32)$$

$$\begin{bmatrix} \sigma_{11} & \sigma_{12} & \dots & \sigma_{1m} \\ \sigma_{21} & \sigma_{22} & \dots & \sigma_{2m} \\ \dots & \dots & \ddots & \dots \\ \sigma_{n1} & \sigma_{n2} & \dots & \sigma_{nm} \end{bmatrix} \begin{bmatrix} u_1 \\ u_2 \\ \dots \\ u_n \end{bmatrix} = \lambda \begin{bmatrix} u_1 \\ u_2 \\ \dots \\ u_n \end{bmatrix} \quad (33)$$

Daha sonra Formül (33)'te verildiği gibi, kovaryans matrisine (C) ait özdeğerler (λ) ve özvektörler hesaplanır. Burada m, değişken sayısı; k, özvektör sayısıdır. Hesaplanan özdeğerler kullanılarak, özvektörlerin matrisi (U) elde edilmektedir.

Formül (34)'te, bileşenlerin hesaplanması için (X) ve (U) matrisi çarpılarak (P) matrisi hesaplanır.

$$P = XU \quad (34)$$

(P) temel bileşen matrisini başlangıçtaki (X) matrisine dönüştürmek için, Formül (35)'teki gibi, (P) matrisini (U^T) matrisi ile çarpmak gerekir.

$$PU^T = X \quad (35)$$

2. YAPILAN ÇALIŞMALAR

Bu bölümde İran'a ait ekonomi ve enerji verileri kullanarak bir tahmin çalışması yapılmıştır. Farklı ekonomi parametreleri kullanarak YSA, YSA zaman serisi yöntemleri ve çoklu regresyon yöntemleri ile İran'ın gelecek yıllardaki net elektrik tüketim tahmini gerçekleştirilmiştir.

2.1. Veri Tabanı

Bu çalışmada kullanılan veriler, literatürde sık kullanılan değişkenlerdir. Bunlardan GSYH, nüfus, ithalat ve ihracat gibi değişkenler birçok çalışmada ortak kullanılmaktadır. Büyüme oranı (BO) ve elektrik satış fiyatı (ESF) ise çok sık kullanılmasa bile birçok makalede elektrik tahmini için kullanılmıştır. Çalışmada İran elektrik enerjisi tahmininde kullanılan bağımlı ve bağımsız değişkenler ve bu değişkenlere ilişkin bilgiler Tablo 7'de verilmiştir.

Tablo 7. Çalışmada kullanılan değişkenlere ilişkin bilgiler

Değişken Sembolü	Değişken Adı	Kaynağı	Değişken kullanılma sebebi
X ₁	GSYH	Dünya Bankası (URL-6, 2015)	GSYH büyüme göstergesi olduğu için paralel olarak elektrik enerjisi tüketimini de göstermektedir.
X ₂	Elektrik satış fiyatı	Elektrik Kurumu (URL-7, 2014)	ESF doğrudan elektrik tüketimini etkilemektedir. Elektrik fiyatı arttıkça elektrik tüketimi azalmaktadır.
X ₃	Nüfus	İran İstatistik Merkezi (URL-8, 2014)	Nüfus oranı arttıkça elektrik tüketiminin de değişmesi beklenmektedir.
X ₄	İthalat	Dünya Bankası (URL-6, 2015)	İthalat verileri ülkenin ekonomisini dolayısıyla elektrik tüketimini de etkilemektedir.
X ₅	İhracat	Dünya Bankası (URL-6, 2015)	Ülkenin ihracat miktarına paralel olarak üretime bağlıdır. Dolayısıyla elektrik tüketiminin bir göstergesidir.
X ₆	Büyüme Oranı	İran İstatistik Merkezi (URL-8, 2014)	Büyüme oranı ülkenin iktisadi durumunun bir göstergesi olduğu için elektrik enerjisini de etkilemektedir.
Y	Elektrik Tüketimi	Elektrik Kurumu (URL-7, 2014)	Bağımlı değişken

1978'den 2014 yılına kadar resmi kaynaklardan elde edilen bağımsız ve bağımlı değişkenler için veriler toplanmış daha sonra MATLAB yazılımı ile elektrik enerji tüketim tahmini için modeller kurulmuştur.

2.2. Yapay Sinir Ağı ile Tahmin

2.2.1. Yapay Sinir Ağının Yapısı

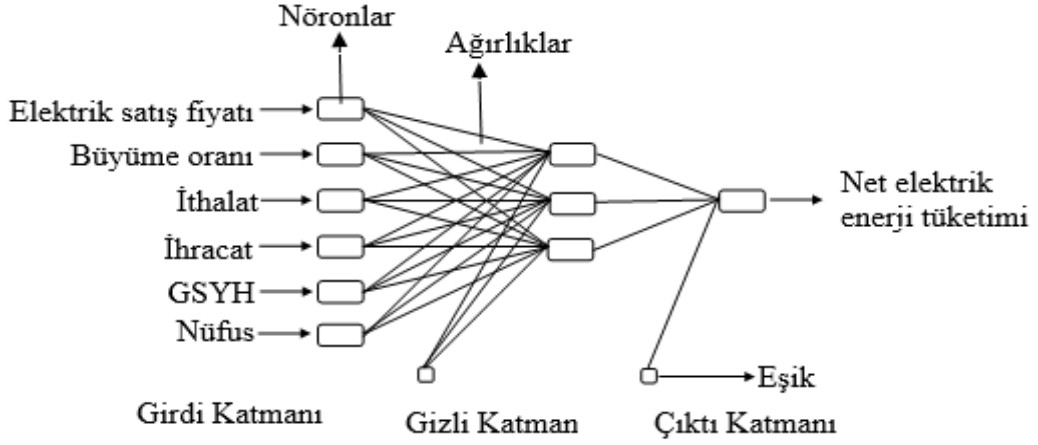
Elektrik satış fiyatı, büyüme oranı, ithalat, ihracat, GSYH ve nüfusun, net elektrik enerji tüketimi değerlerine etkisini incelemek amacıyla; veriler eğitim ve test verileri şeklinde gruplandırılıp, farklı veri setleri oluşturularak yapay sinir ağlarını (YSA) eğitmek için kullanılmıştır. Tahmin modelinde kullanılan veri setleri Tablo 8'de gösterilmiştir.

Değişik ağ yapılarına ve öğrenme parametrelerine sahip farklı modeller kurulup denemeler yapılarak eğitimler gerçekleştirilmiş, ağların performansını test etmek amacıyla eğitim setinde kullanılmayan ve test için ayrılan verilerle modeller test edilerek en hassas sonuç elde edilmeye çalışılmıştır.

Test işlemi sonucunda bulunan tahmini değerler gerçek değerlerle karşılaştırılmış, 7 numaralı eşitlikle hesaplanan ortalama hata karenin karekökü (root mean square error) (RMSE) ve 6 numaralı eşitlikle hesaplanan ortalama mutlak yüzde hata (mean absolute percentage error) (MAPE) oranları dikkate alınarak en iyi tahmin değerlerini veren model, tahmin modeli olarak seçilmiştir. Tablo 8'de, bu tahmin modeli kullanılarak hesaplanan değerler, gerçek değerler, mutlak yüzde hata oranları ile RMSE ve MAPE değerleri görülmektedir.

Problemin çözümünde ileri beslemeli ve geri yayımlı (FeedForward and BackPropagation) çok katmanlı (multilayer) YSA (ANN) tercih edilmiş, ağların eğitimi ve denenmesi MATLAB programında yazılan kodlar ile gerçekleştirilmiştir.

Şekil 8'de tahmin modeli olarak seçilen ve gerçek değerlere en yakın sonuçları veren 1 giriş katmanı, 1 gizli katman ve 1 çıkış katmanından oluşan YSA modeli görülmektedir. Modelde elektrik satış fiyatı, büyüme oranı, ithalat, ihracat, GSYH ve nüfus girdi değişkenleri, net elektrik enerji tüketimi ise çıktı değişkeni olarak alınmıştır. Gizli katmandaki işlem elamanı (nöron) sayısı 3'tür.




Şekil 8. Elektrik tüketim tahmini için kurulan modelin yapısı

Bu çalışmada, aktivasyon (activation) (transfer) fonksiyonu olarak hiperbolik tanjant sigmoid fonksiyonu (hyperbolic tangent sigmoid function) (tansig) ile doğrusal transfer fonksiyonu (linear transfer function) (purelin), eğitim algoritması olarak da levenberg marquardt algoritması (trainlm) seçilmiş, performans fonksiyonu olarak da ortalama karesel hata (mean square error) (MSE) kullanılmıştır.

2.2.2.Yapay Sinir Ağı Modelinin Eğitim Sonuçları

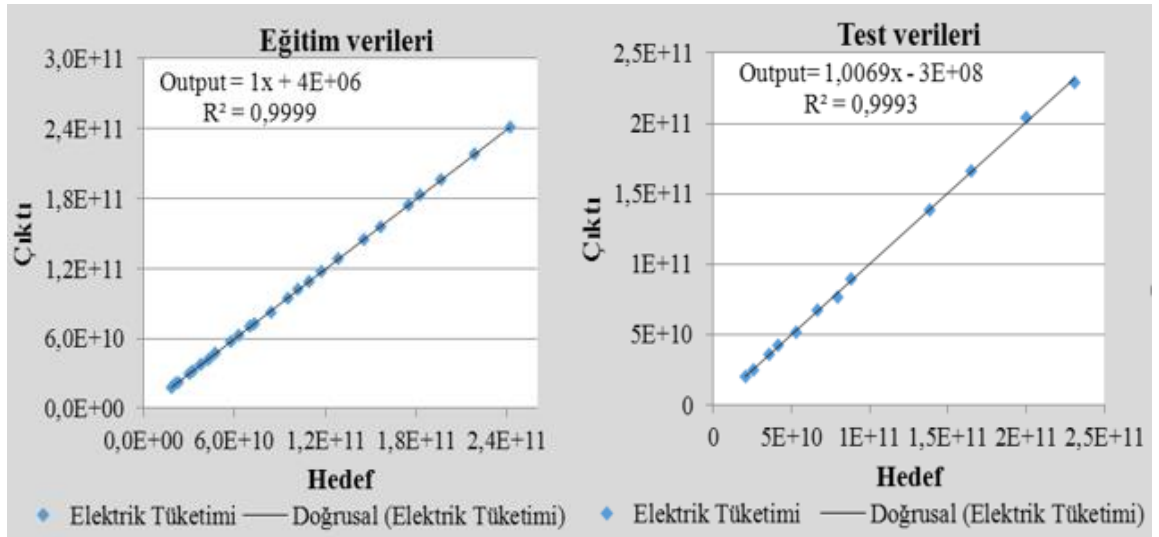
Seçilen yapay sinir ağının iterasyona bağlı hata değişim grafiği Şekil 9'da görülmekte olup, modelin eğitiminin durduğu döngü sayısı 75'tir.

Yapay sinir ağı tahmin modeli için performans fonksiyonu olarak hata kareleri ortalaması (MSE) kullanılmıştır. MSE (5) numaralı eşitlikle hesaplanmaktadır.

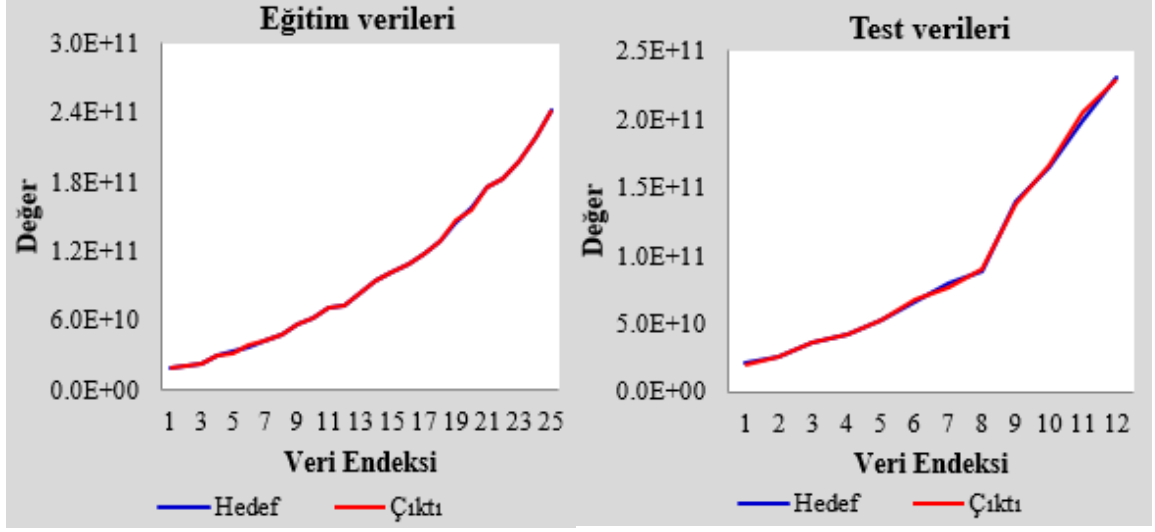


Şekil 9. Eğitim kümesine ilişkin hata performansı

Tahmin modeli kullanılarak hesaplanan değerler ile gerçek değerler arasındaki ilişki eğitim ve test kümesi için Şekil 10'da görülmektedir. Bu değerlerin karşılaştırılmalı grafikleri de Şekil 11'de verilmiştir.



Şekil 10. Öğrenme ve test kümelerine ilişkin regresyon grafikleri



Şekil 11. Gerçek değerler ile tahmin değerlerin kıyaslanması

Tablo 8’de eğitim ve test kümesinde kullanılan veriler gösterilmektedir. İtalik olarak yazılan veriler test kümesi verilerini, normal yazılan veriler ise eğitim kümesi verilerini göstermektedir.

Tablo 8 incelendiğinde YSA tahmin modeli kullanılarak hesaplanan değerlerin gerçek değerlere çok yakın olduğu görülmektedir. Eğitim ve test seti için mutlak yüzde hata oranları sırasıyla %3.078ve %2.456’yi aşmamaktadır.

Bu değerler ve karşılaştırmalar ağırlıklı bir şekilde duyarlı sonuçlar ürettiğini ve net elektrik enerji tüketiminin modellenmesi için yeterli doğruluğa ve güvenilirliğe sahip olduğunu göstermektedir.

Tablo 8. Modelde kullanılan eğitim ve test kümesi setleri ile tahmin modeli sonuçları

Yıl	GSYH	Nüfus	ESF	BO	İthalat	İhracat	ET	Tahmin	APE
	(Milyar dolar)	(Milyon)	(Dolar/KWH)		(Milyar dolar)	(Milyar dolar)	(GWH)	(GWH)	
1978	102.666	36.17	0.033	-6%	15.573	18.329	18409	18476.13	0.365%
1979	95.352	37.46	0.033	-4%	13.044	24.203	20692	20804.39	0.021%
1980	82.737	38.89	0.040	-8%	24.375	12.976	20800	22399.02	0.045%
1981	78.436	40.44	0.040	-4%	12.445	25.235	22409	29773.77	0.050%
1982	88.598	42.10	0.048	13%	21.585	23.736	25662	32171.59	1.323%
1983	99.769	43.85	0.044	11%	22.751	33.997	29759	37931.01	1.493%
1984	98.199	45.67	0.039	-2%	18.379	24.236	32603	42267.83	0.724%
1985	100.227	47.53	0.045	2%	16.024	23.135	35486	47314.97	0.320%
1986	91.035	49.44	0.055	-9%	7.811	19.565	37373	57379.42	0.023%
1987	89.758	51.38	0.074	-1%	12.285	10.509	41347	62684.93	0.118%
1988	84.104	53.25	0.089	-6%	8.975	15.811	42576	70220.28	0.119%
1989	89.299	54.94	0.077	6%	11.576	19.807	47164	72969.77	0.298%
1990	101.523	56.36	0.095	14%	16.853	26.845	53034	83085.73	0.978%
1991	114.309	57.47	0.142	12%	18.449	31.027	57366	95042.07	0.025%
1992	119.168	58.31	0.007	4%	19.645	27.168	62611	102269.17	0.771%
1993	117.290	58.98	0.010	2%	16.468	11.920	66501	108893.52	0.318%
1994	116.879	59.66	0.019	1%	20.376	8.753	70137	117234.82	0.166%
1995	119.979	60.47	0.022	3%	19.718	11.913	72753	128787.39	0.097%
1996	128.499	61.44	0.027	6%	23.039	16.545	79649	145520.45	0.307%
1997	132.848	62.54	0.032	3%	18.351	16.092	83906	155954.25	0.486%
1998	136.489	63.71	0.038	3%	13.992	16.085	88295	174933.68	0.123%
1999	139.129	64.86	0.046	2%	22.413	15.563	95018	183104.81	0.200%
2000	146.284	65.91	0.051	5%	23.000	17.657	101487	196135.94	0.033%
2001	151.652	66.86	0.056	3%	23.669	21.688	109241	218785.22	0.059%
2002	163.050	67.73	0.014	8%	30.896	26.460	117430	241922.20	0.000%
2003	174.650	68.54	0.016	8%	36.877	34.805	128663	20363.79	1.586%
2004	183.530	69.34	0.017	6%	47.413	42.322	138559	25031.68	2.456%
2005	192.015	70.15	0.017	7%	63.474	47.347	1450750	35855.03	1.040%
2006	203.332	70.98	0.017	7%	72.326	54.415	156716	42358.47	2.446%
2007	216.275	71.81	0.018	5%	92.050	61.612	164594	51874.58	2.186%
2008	219.558	72.66	0.018	1%	95.153	70.102	174718	67887.00	2.084%
2009	224.563	73.54	0.017	3%	67.346	55.141	182739	77197.42	3.078%
2010	239.450	74.46	0.020	6%	84.107	55.189	196201	89744.97	1.642%
2011	248.899	75.42	0.039	3%	88.197	64.364	199787	138217.01	0.247%
2012	232.560	76.42	0.033	-5%	76.511	61.823	218915	166543.58	1.184%
2013	228.104	77.45	0.020	-2%	61.100	53.348	230972	204482.21	2.350%
2014	231.432	78.15	0.020	3%	73.038	50.818	241921	229112.01	0.805%
Eğitim kümesi (MAPE)									0.338%
Test kümesi (MAPE)									1.758%
Eğitim kümesi (RMSE)									353231538.8
Test kümesi (RMSE)									1881146582

2.2.3. Yapay Sinir Ağı Modelinin Tahmin İşlemi

Gelecekteki elektrik enerjisi tüketimini tahmin edebilmek için YSA modelinde kullanılan elektrik satış fiyatı, büyüme oranı, ithalat, ihracat, GSYH ve nüfus değişkenlerinin gelecekteki değerlerinin bilinmesi gerekmektedir. Bu yüzden 3 farklı senaryo (düşük, beklenen, yüksek senaryo) oluşturularak bu senaryolara göre girdi değişkenlerinin gelecekteki değerleri belirlenerek, çıktı değişkeni olan net elektrik enerji tüketiminin tahmini yapılmıştır.

2.2.3.1. Senaryolar

Senaryoları belirlemek için girdi olarak kullanılan altı değişkenin her bir yıldaki değerlerinin bir önceki yıldaki değerlerine göre artış oranları tespit edilmiş, daha sonra parametre değerlerindeki en yüksek ve en düşük artış oranları ile ortalama artış oranları hesaplanmıştır.

Düşük, yüksek ve ortalama (beklenen) senaryolar için parametrelere ait olan yıllar arasındaki sırasıyla en düşük, en yüksek ve ortalama artış oranına sahip olan yılların artış oranları seçilmiştir.

Senaryoları belirlerken “elektrik satış fiyatı” değişkeni için farklı bir yaklaşım uygulanmıştır. Elektrik satış fiyatı elektrik tüketimi ile ters orantılıdır, yani elektrik satış fiyatı arttıkça, elektrik tüketimi azalmaktadır. Dolayısıyla ESF senaryosunda diğer değişkenlerin aksine en yüksek ve en düşük artış oranı, sırasıyla düşük ve yüksek senaryo için kullanılmıştır.

Üç senaryo ile 2021 yılına kadar elektrik tüketiminin tahmini yapılmıştır. En düşük değer düşük senaryo (DS), en yüksek değer yüksek senaryo (YS) ve ortalama değer ise beklenen senaryo (BS) olarak adlandırılmıştır ve bu değerler Tablo 9’da verilmiştir.

Tablo 9. Senaryolar ve yüzdeler

Senaryolar	Nüfus	İthalat	İhracat	GSYH	ESF	Büyüme oranı
Düşük senaryo	0.01%	0.03%	0.12%	0.01%	0.94%	0.5%
Beklenen senaryo	0.02%	0.27%	0.26%	0.06%	0.26%	5.36%
Yüksek senaryo	0.04%	0.87%	0.94%	0.14%	0.02%	14.10%

Tablo 9'daki veriler kullanarak Tablo 10 - 12'deki senaryo deęerleri elde edilmiřtir.

Tablo 10. Düşük senaryo deęerleri

Düşük senaryo						
Yıllar	Nüfus (Milyon)	İthalat (Milyar dolar)	İhracat (Milyar dolar)	GSYH (Milyar dolar)	ESF (Dolar/KWH)	BO
2015	78.932	75.229	56.916	233.746	0.0379	0.5
2016	79.721	77.486	63.746	236.084	0.0736	0.5
2017	80.518	79.811	71.396	238.445	0.1428	0.5
2018	81.323	82.205	79.963	240.829	0.2770	0.5
2019	82.136	84.671	89.559	243.237	0.5374	0.5
2020	82.958	87.211	100.306	245.670	1.0426	0.5
2021	83.787	89.828	112.343	248.126	2.0226	0.5

Tablo 11. Beklenen senaryo deęerleri

Beklenen senaryo						
Yıllar	Nüfus (Milyon)	İthalat (Milyar dolar)	İhracat (Milyar dolar)	GSYH (Milyar dolar)	ESF (Dolar/KWH)	BO
2015	81.276	136.581	99.604	263.832	0.025	5.36
2016	84.527	255.407	195.223	300.769	0.031	5.36
2017	87.908	477.612	382.637	342.877	0.039	5.36
2018	91.424	893.134	749.968	390.879	0.049	5.36
2019	95.081	1670.160	1469.938	445.603	0.062	5.36
2020	98.885	3123.199	2881.079	507.987	0.078	5.36
2021	102.840	5840.383	5646.915	579.105	0.099	5.36

Tablo 12. Yüksek senaryo deęerleri

Yüksek Senaryo						
Yıllar	Nüfus (Milyon)	İthalat (Milyar dolar)	İhracat (Milyar dolar)	GSYH (Milyar dolar)	ESF (Dolar/KWH)	BO
2015	79.713	92.759	64.031	245.318	0.0199	14.1
2016	81.307	117.803	80.679	260.037	0.0203	14.1
2017	82.933	149.610	101.655	275.639	0.0208	14.1
2018	84.592	190.005	128.086	292.178	0.0212	14.1
2019	86.284	241.306	161.388	309.708	0.0216	14.1
2020	88.010	306.459	203.349	328.291	0.0220	14.1
2021	89.770	389.203	256.220	347.988	0.0225	14.1

2.2.4. Senaryolara Göre Yapay Sinir Ağı Tahmin Değerleri

Parametrelerin değerleri, gelecekteki 7 yıl için senaryolar dikkate alınarak hesaplanmış ve 10, 11, 12 Tablolarında verilmiştir. YSA tahmin modeli yardımıyla hesaplanan gelecek 7 yıldaki elektrik tüketimin tahmini değerleri düşük, beklenen ve yüksek senaryo için belirlenerek Tablo 13'te gösterilmiştir.

Tablo 13. Farklı senaryolara göre elektrik tüketim tahmin değerleri

Yıllar	Düşük senaryo (KWH)	Beklenen senaryo (KWH)	Yüksek senaryo (KWH)
2015	253219548469.97	265296461706.37	290211370247.25
2016	264089262889.14	294114364358.22	384281529351.46
2017	276707638736.52	329400217248.24	536584897672.13
2018	293401857591.23	372743192680.94	720098469463.96
2019	319194341809.45	425033484637.53	843588660014.84
2020	364267491806.89	486194765406.87	873859777952.31
2021	446023843589.93	554854743717.89	875548639791.03

2.2.5. Yapay Sinir Ağı Modelinin Ağırlık Değerleri

YSA modelinin eğitim sürecinde, en uygun ağırlık değerleri (bağlantı ağırlıkları) bulanana kadar ağırlık değerleri sürekli değişmektedir. Eğitimin durdurulması, hatanın belirlenen bir seviyenin altına inmesi veya ağırlıklarındaki değişim miktarının önemsenmeyecek derecede küçük bir değer almaya başlaması ile sağlanmaktadır. Kurulan YSA modeli için ağırlık değerleri, MATLAB yazılımında hesaplanmıştır. Eşik, gizli ve çıktı katman için ağırlık değerleri Tablo 14'de verilmektedir.

Tablo 14. YSA modelinin ağırlık değerleri

Girdi katman							Gizli katman	
Nöron1	Nöron2	Nöron3	Nöron4	Nöron5	Nöron6	Eşik	Nöron1	Eşik
0.117	-0.8222	-0.0098	0.0185	-0.0802	0.0272	1.0653	-4.544	2.727
-0.6457	1.6163	0.0599	-0.0771	0.3046	0.0652	-00.5044	-0.726	
2.8451	-0.9084	0.2203	-0.1189	-1.3206	1.7794	0.1657	0.124	

2.3. Yapay Sinir Ağı ile Zaman Serisi Tahmini

Bu yöntem yapısal olarak sebep-sonuç yöntemine benzemektedir ve yöntemin tek farkı geçmiş verilerin, çıktı verilerine göre belirli gecikme zamanları göz önüne alınarak, girdi olarak ağa verilmesidir.

Zaman serisinde maksimum ileriye doğru yapabileceğimiz statik tahmin sayısı, en küçük gecikme değeri kadardır.

Çalışmanın bu kısmında YSA zaman seri yöntemi ile net elektrik enerji tüketiminin geçmiş yıllara ait verileri kullanılarak gelecek yıllardaki net elektrik enerji tüketimi miktarı tahmin edilmektedir.

Geçmiş 37 yıla ait yıllık verilerle bir, iki ve üç dönemli (yıllık) gecikmeler belirleyerek, üç girdi nöronu ile ağın eğitimi gerçekleştirilmiştir. Girdi katmanındaki nöronların sayısı gecikme sayısı kadar olup, gecikme sayısı arttıkça, toplam gecikme sayısı kadar gözlem sayısının azalmasına neden olur.

Problemin çözümünde ileri beslemeli ve geri yayımlı çok katmanlı YSA tercih edilmiş, ağların eğitimi ve denenmesi MATLAB paket programı ile gerçekleştirilmiştir.

2.3.1. Yapay Sinir Ağı Zaman Serisi Modelinin Yapısı

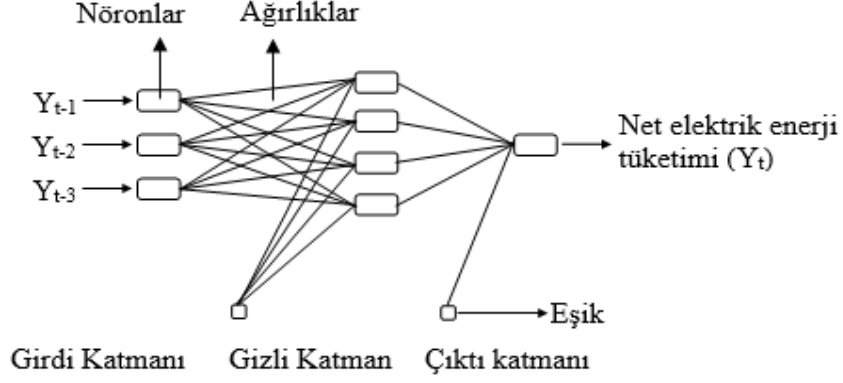
Veriler eğitim ve test veri setleri şeklinde ayrılarak yapay sinir ağlarını eğitmek için kullanılmıştır. Denemeler yapılarak eğitimler gerçekleştirilmiş, modeller test edilerek en hassas sonuç elde edilmeye çalışılmıştır.

Test işlemi sonucunda bulunan tahmini değerler gerçek değerlerle karşılaştırılmış ortalama karesel hatanın karekökü ve ortalama mutlak yüzde hata oranları dikkate alınarak en iyi tahmin değerlerini veren model, tahmin modeli olarak seçilmiştir. Tablo 15'te, YSA zaman serisi tahmin modeli kullanılarak hesaplanan değerler, gerçek değerler, mutlak yüzde hata oranları ile RMSE ve MAPE değerleri görülmektedir.

Şekil 12'de YSA zaman serisi tahmin modeli olarak seçilen ve gerçek değerlere en yakın sonuçları veren 1 giriş katmanı, 1 gizli katman ve 1 çıkış katmanından oluşan YSA modeli görülmektedir. Gizli katmandaki işlem elemanı sayısı 4' tür.

Tahmin modelinde, aktivasyon fonksiyonu olarak hiperbolik tanjant sigmoid fonksiyonu ile doğrusal transfer fonksiyonu, eğitim algoritması olarak da levenberg marquardt algoritması seçilmiş, öğrenme kuralı olarak momentumlugradyanazaltım geri


yayılm algoritması, performans fonksiyonu olarak da ortalama karesel hata kullanılmıştır. Zaman serisi tahmini için kurulan ÇKA, Şekil 12’de verilmiştir.



Şekil 12. Zaman serisi tahmini için kurulan ÇKA


2.3.2. Yapay Sinir Ağı Zaman Serisi Modelinin Eğitim Sonuçları

Seçilen yapay sinir ağının iterasyona bağlı hata değişim grafiği Şekil 13’te görülmekte olup, modelin eğitiminin durduğu döngü sayısı 951 dir. YSA zaman serisi tahmin modeli için performans fonksiyonu olarak hata kareleri ortalaması (MSE) kullanılmıştır.




Şekil 13. Eğitim kümesine ilişkin hata performansı

Tahmin modeli kullanılarak hesaplanan değerler ile gerçek değerler arasındaki ilişki eğitim ve test kümesi için Şekil 14'te görülmektedir. Bu değerlerin karşılaştırılması grafikleri de Şekil 15'te verilmiştir.



Şekil 14. Öğrenme ve test kümelerine ilişkin regresyon grafikleri



Şekil 15. Gerçek değerler ile tahmin değerlerin kıyaslanması

Tablo 15. Zaman Serisi tahmin modelinde kullanılan eğitim ve test kümesi verileri ile tahmin modeli sonuçları

Yıl	Elektrik tüketimi (GWH)	Tahmin (GWH)	APE
1981	22409	23699.85926	5.76%
1982	25662	24649.11906	3.95%
1983	29759	29082.31162	2.27%
1984	32603	32946.95314	1.05%
1985	35486	34548.27455	2.64%
1986	37373	37884.92537	1.37%
1987	41347	40714.98988	1.53%
1988	42576	44119.82789	3.63%
1989	47164	47048.82352	0.24%
1990	53034	53126.1806	0.17%
1991	57366	57311.7123	0.09%
1992	62611	62103.24954	0.81%
1993	66501	66453.90994	0.07%
1994	70137	70102.22279	0.05%
1995	72753	72749.09994	0.01%
1996	79649	79718.67689	0.09%
1997	83906	83727.601	0.21%
1998	88295	88729.56802	0.49%
1999	95018	94508.1602	0.54%
2000	101487	101215.3187	0.27%
2001	109241	109377.3227	0.12%
2002	117430	118264.9823	0.71%
2003	128663	128139.9751	0.41%
2004	138559	138535.7788	0.02%
2005	145075	145061.3284	0.01%
2006	156716	155549.9781	0.74%
2007	164594	165849.0751	0.76%
2008	174718	176851.6459	1.22%
2009	182739	186751.9245	2.20%
2010	196201	196254.2799	0.03%
2011	199787	206476.1605	3.35%
2012	218915	215074.9819	1.75%
2013	230972	227481.4104	1.51%
2014	241921	236443.0955	2.26%
Eğitim kümesi (MAPE)			1.06%
Test kümesi (MAPE)			1.54%
Eğitim kümesi (RMSE)			600932453.5
Test kümesi (RMSE)			3730890992

Tablo 15'te eğitim ve test kümesinde kullanılan veriler gösterilmektedir. İtalik olarak yazılan veriler test kümesi verilerini, normal yazılan veriler ise eğitim kümesi verilerini

göstermektedir. Tablo 15 incelendiğinde YSA tahmin modeli kullanılarak hesaplanan değerlerin gerçek değerlere çok yakın olduğu görülmektedir. Eğitim ve test seti için mutlak yüzde hata oranları sırasıyla %5.76 ve %3.35'i aşmamaktadır. Bu değerler ve karşılaştırmalar ağın etkili bir şekilde duyarlı sonuçlar ürettiğini ve net elektrik enerji tüketiminin modellenmesi için yeterli doğruluğa ve güvenilirliğe sahip olduğunu göstermektedir.

Modelleme için kullanılan gecikmelerin belirlenmesinde farklı gecikme sayıları denenmiştir. Her gecikme için hata oranları gözden geçirilerek en iyi olan ve kabul edilebilir performansa sahip gecikme sayısı üç gecikme olarak belirlenmiştir. Bu çalışmada tahmin işlemi için hesaplanan gecikmeler Tablo 16'da sunulmuştur.

Tablo 16. 2015 ile 2021 yılları tahmin işlemi için hesaplanan gecikmeler

Gecikmeler			
t-3	t-2	t-1	t
1978	1979	1980	1981
1979	1980	1981	1982
·	·	·	·
·	·	·	·
·	·	·	·
2012	2013	2014	2015
2013	2014	2015	2016
2014	2015	2016	2017
2015	2016	2017	2018
2016	2017	2018	2019
2017	2018	2019	2020
2018	2019	2020	2021

YSA zaman serisi tahmin modeli yardımıyla hesaplanan gelecek 7 yıldaki elektrik tüketiminin tahmin değerleri Tablo 17'de verilmektedir.

Tablo 17. YSA zaman serisi modelinin tahmin değerleri

Yıllar	Tahmin (KWH)
2015	245464460432
2016	251029097634
2017	254248782994
2018	257013032974
2019	258964765978
2020	260420333710
2021	261472462711

2.3.3. Yapay Sinir Ağı Zaman Serisi Modelinin Ağırlık Değerleri

YSA zaman serisi tahmin modelinin eğitim sürecinde, en uygun ağırlık değerleri bulunmuş ve Tablo 18’de verilmiştir.

Tablo 18. Zaman serisi YSA modelinin ağırlık değerleri

Girdi katman					Gizli katman	
Nöron1	Nöron2	Nöron3	Nöron4	Eşik	Nöron1	Eşik
0.04943	0.30122	0.23429	0.15687	0.15687	1.99678	-0.2308
-154.785	656.939	-485.28	31.6268	31.6268	-0.0144	
143.6502	228.048	-530.61	-86.454	-86.454	0.02852	
-17.1625	-17.543	-28.552	1.15603	1.15603	0.03458	

2.4. Çoklu Doğrusal Regresyon Modeli

YSA ile yapılan tahminlerin başarısını ölçmek için bu çalışmada kullanılan bir başka yöntem de çoklu doğrusal regresyon yöntemidir. YSA modelinde kullanılan bağımsız değişkenler, MINITAB programında analiz edilerek çoklu doğrusal regresyon modeli kurulmuştur.

Çoklu doğrusal regresyon yöntemini diğer yöntemlerle karşılaştırmak amacı ile toplam 37 tane veriden son 12 adedi test verisi olarak ayrılmıştır. Elde edilen regresyon denkleminin güvenilirliğini belirlemek için test verileri, regresyon denklemi ile hesaplanarak çıktı değerleri gerçek değerler ile kıyaslanmıştır. Kurulan modelin başarısını ölçmek için APE ve MAPE performans ölçütleri kullanılmıştır.

Değişkenlerin regresyon modelinde kullanılması için normal dağılım gösterip göstermediği araştırılmıştır. Fakat değişkenler bu özelliği sağlamadıklarından, veriler normalize edildikten sonra çoklu regresyon analizine tabi tutulmuş ve ilk sonuçlar Tablo 19’da gösterilmiştir.

GSYH (X_1), “Nüfus (X_2)”, “Elektrik Satış Fiyatı (X_3)”, “Büyüme Oranı (X_4)”, “İthalat (X_5)” ve “İhracat (X_6)” değişkenleri YSA modelinde olduğu gibi regresyon modelinde de bağımsız değişken olarak kullanılmıştır. Bağımlı değişken olarak da “Elektrik Enerjisi Tüketimi” değişkeni kullanılmıştır.

Tablo 19. Regresyon modelinin sonuçları

Değişkenler	Katsayısı	Standart hata	T	P	VIF
Sabit	43.406	0.637	68.14	0	
X ₁	-0.2852	0.0392	-7.28	0	6.19
X ₂	-1.8607	0.0426	-43.7	0	6.52
X ₃	-0.00507	0.00213	-2.38	0.029	1.58
X ₄	0.000757	0.000909	0.83	0.416	3.21
X ₅	0.00446	0.0043	1.04	0.314	3.14
X ₆	-0.0009	0.014	-0.06	0.952	2.18

Modelin bağımsız değişkenlerinin bazıları (X₃, X₄, X₅, X₆) için P>0.01 olduğundan söz konusu değişkenlere ait katsayılar istatistiksel olarak anlamsızdır. Ayrıca bağımsız değişkenler arasında çoklu bağlantı (multicollinearity) olup olmadığını gösteren VIF değerlerine göre 5'ten büyük VIF değerine sahip iki değişken arasında yakın doğrusal bağıllık vardır.

Bu problemin çözülmesi için VIF değerleri yüksek olan değişkenlerin modelden çıkartılması mümkündür, ancak bu çalışmada ÇDR modellerinin kullanım amacı, sebep-sonuç yöntemi ile bir karşılaştırma yapmak olduğundan bazı değişkenlerin kullanılmasıyla elde edilen sonuçlar, karşılaştırma yapmak için yeterli ve sağlıklı olmamaktadır. Karşılaştırma yapabilmek için altı değişkenin de kullanılması gerektiğinden yüksek VIF değeri sorununu Temel Bileşen Analizi (TBA) ile çözülmüştür. Karşılaştırmada kullanılan regresyon denklemi TBA'dan elde edilen skorlar kullanılarak oluşturulmuştur. Bağımlı değişkenin (Elektrik Enerjisi Tüketimi) gelecekteki değeri, bağımsız değişkenlerin gelecekteki değerlerinin, TBA'dan elde edilen özvektörlerle çarpılarak bileşenlerin değerlerinin hesaplanmasıyla elde edilmiştir. TBA özvektör değerleri Tablo 20'de verilmiştir.

Tablo 20. TBA sonucunda elde edilen özvektör değerleri

Değişkenler	Bileşen1	Bileşen2	Bileşen3	Bileşen4	Bileşen5	Bileşen6
X ₁	0.012634	0.033856	0.069392	0.154191	0.732415	-0.65854
X ₂	0.012955	0.034915	-0.0071	0.300112	0.600899	0.739875
X ₃	0.094421	0.985148	-0.13409	-0.03811	-0.03293	-0.00722
X ₄	0.988738	-0.1079	-0.09889	0.024629	-0.01659	-0.00968
X ₅	-0.11249	-0.1201	-0.98275	0.049446	0.040775	-0.05496
X ₆	0.022394	-0.03242	-0.03978	-0.93896	0.315381	0.125483

TBA sonucu elde edilen skorlar Tablo 21’de görülmektedir.

Tablo 21. TBA sonucunda elde edilen skorlar


Yıllar	Bileşen 1	Bileşen 2	Bileşen 3	Bileşen 4	Bileşen 5	Bileşen 6
1978	-5.5934	2.1111	-6.8209	-12.8751	36.8497	-1.2500
1979	-3.6958	1.7735	-7.7615	-13.0502	36.9021	-1.2006
1980	-7.4162	2.3524	-5.0206	-12.6844	36.5997	-0.9886
1981	-3.8035	5.0393	-8.3851	-13.2219	36.7246	-1.0415
1982	13.2032	2.9998	-7.8713	-12.8033	36.4645	-1.1423
1983	11.7690	3.3750	-7.5826	-13.1635	36.7003	-1.1224
1984	-1.2467	5.0017	-7.0482	-13.1329	36.8444	-1.0406
1985	2.6180	4.1870	-7.9111	-12.9372	36.8345	-1.0956
1986	-8.7887	4.5283	-10.1085	-12.8700	37.0733	-1.1010
1987	-0.5908	3.3750	-8.5547	-12.1687	36.6815	-1.0895
1988	-5.2351	3.3363	-9.5935	-12.5739	36.9322	-1.0072
1989	6.2093	2.5112	-9.5214	-12.5584	36.8167	-1.0383
1990	14.4707	1.4580	-8.7236	-12.6795	36.8329	-1.0550
1991	12.4807	1.1318	-8.1093	-12.8348	37.0159	-1.0582
1992	5.3539	10.9973	-8.2956	-13.2566	36.8388	-1.0663
1993	2.5653	8.8753	-8.3449	-12.4207	36.7208	-1.1455
1994	1.4668	7.0906	-7.1887	-12.1140	36.6790	-1.1059
1995	3.7742	6.1833	-7.4655	-12.3063	36.7893	-1.0995
1996	6.9515	5.3196	-7.1880	-12.5247	36.8971	-1.0892
1997	3.5487	5.0539	-7.5664	-12.5097	37.0282	-1.1092
1998	3.4817	4.4379	-8.5632	-12.4256	37.1170	-1.1697
1999	2.3542	4.3600	-6.6291	-12.4894	37.0951	-1.0600
2000	5.7062	3.7625	-6.8503	-12.5065	37.1294	-1.0917
2001	4.0213	3.7444	-6.5673	-12.7282	37.2605	-1.0560
2002	9.3520	7.3704	-6.8109	-12.9764	37.1340	-1.1018

Tablo 22’de belirlendiği gibi bütün girdi değişkenleri, TBA yöntemini kullandıktan sonra her bir bileşen için $P < 0.01$ olduğundan istatistiksel olarak anlamlıdır ve varyans artış faktörü (VIF) değerleri 5’ten küçük olması nedeni ile bileşenler arasında çoklu bağlantı bulunmamaktadır.

Tablo 22. TBA bileşenleri ile kurulan regresyon modeli

Değişkenler	Katsayısı	Standart hata katsayısı	T	P	VIF
Sabit	43.342	0.716	60.57	0	
Bileşen1	-0.027826	0.000564	-49.35	0	1
Bileşen2	-0.07743	0.00156	-49.6	0	1
Bileşen3	-0.01129	0.00328	-3.44	0.003	1
Bileşen4	-0.6134	0.0114	-53.84	0	1
Bileşen5	-1.3294	0.0189	-70.34	0	1
Bileşen6	-1.1712	0.0625	-18.75	0	1
Durbin Watson istatistiği = 1.44733					

Regresyon modeli altı bileşen ile kurulduğunda, 25 gözlem sayısı için Durbin-Watson tablo değeri $d_L = 0.682$ ve $d_U = 1.776$ 'dır. Regresyon modelinden elde edilen Durbin-Watson değeri 1.44733'tür. Bu değer Şekil 16'da görüldüğü gibi kabul bölgesinde değildir.



Şekil 16. Durbin-Watson testi kararlarının şematik gösterimi (URL-9, 2015).

Problemi çözmek için MİNİTAB programının verdiği sonuçlar göz önünde bulundurularak, on beşinci yıla ait veriler göz ardı edilmektedir.

Son aşamada regresyon modeli altı bileşen ile kurulmuştur ve tahmin işlemi için regresyon denklemi elde edilmiştir.

24 gözlem sayısı için Durbin-Watson tablo değeri $d_L = 0.652$ ve $d_U = 1.797$ 'tir. Regresyon modelinden elde edilen Durbin-Watson değeri 1.84882'dir. Bu değer Şekil 21'de görüldüğü üzere kabul bölgesindedir. Regresyon denklem sonuçları Tablo 23'te görülmektedir.

Tablo 23. Regresyon analiz sonuçları

Tahmin değişkenleri	Katsayı	Standart hata katsayısı	T	P	VIF
Sabit	43.406	0.637	68.14	0	
Bileşen1	-0.02796	0.000505	-55.41	0	1.01
Bileşen2	-0.08021	0.00181	-44.4	0	1.11
Bileşen3	-0.01033	0.00294	-3.51	0.003	1.01
Bileşen4	-0.6012	0.0113	-53.02	0	1.09
Bileşen5	-1.3269	0.0168	-78.8	0	1
Bileşen6	-1.1892	0.0561	-21.21	0	1.01
S = 0.0158422	R-kare = 99.9%		R-kare (düzeltilmiş) = 99.86%		
Varyans Analizi					
Kaynak	DF	SS	MS	F	P
Regresyon	6	9.65933	1.60989	6658.2	0
Durbin-Watson istatistiği = 1.84882					
Regresyon denklemi					
Y= 43.406 - 0.027960 Bileşen1 - 0.08021 Bileşen2 - 0.01033 Bileşen3 - 0.6012Bileşen 4 - 1.3269 Bileşen5- 1.1892 Bileşen6"					

Sonuçlara göre tüm girdi değişkenleri ve model anlamlıdır. Elde edilen regresyon denklemi ile, YSA'da uygulandığı gibi, belirlenen üç senaryoya ait veriler kullanarak gelecekteki elektrik enerji tüketimin tahmini gerçekleştirilmiştir. Üç farklı senaryoya göre elektrik enerjisi tüketimi tahminleri Tablo 24'te verilmiştir.

Tablo 24. TBA ile regresyon analizi sonucunda elde edilen tahmini değerler

Yıllar	Düşük senaryo (KWH)	Beklenen senaryo (KWH)	Yüksek senaryo (KWH)
2015	248033163446.57	267403152182.13	301499204622.43
2016	255444430610.56	298268133303.87	387545173957.13
2017	264263401148.60	333802328123.44	505009266542.68
2018	274312903615.38	374866846250.90	668669228920.79
2019	285480680882.21	422513194135.31	901981953122.97
2020	297700529929.18	478032648113.49	1243385624828.18
2021	310940056899.60	543020453462.35	1758213913807.97

3. SONUÇ VE ÖNERİLER

3.1. Sonuç

Girdiler ve çıktılar arasındaki ilişkinin karmaşıklığı göz önüne alındığında yapay sinir ağları tahmin modelleriyle elde edilen sonuçlar son derece memnuniyet verici ve yeterlidir. Şekil 10 ve 14’te net elektrik enerjisi için sırasıyla YSA sebep sonuç ve YSA zaman serisi modellerinin tahmini değerleri ile gerçek değerlerin dağılım diyagramları gösterilmektedir. Sonuçlar yapay sinir ağları modelleri ile tahmin edilen ve gerçek net elektrik enerjisi tüketimi değerleri arasında çok yüksek bir R^2 ilişkisinin olduğunu göstermektedir. YSA sebep sonuç ve YSA zaman serisi modellerinin test seti için sırasıyla %1.76 ve %1.54 olan MAPE değerleri de tahmin modellerinin kabul edilebilirliğini desteklemektedir. YSA sebep sonuç yönteminde test ile eğitim kümelerinde kullanılan yıllar rastgele seçildiğinden YSA zaman serisi ve çoklu doğrusal regresyon yöntemlerindeki test ve eğitim kümelerinde kullanılan yıllardan farklıdır. Bu nedenle sonuçlar iki tabloda sunulmuştur. Çalışmadaki modellerden elde edilen tahmini değerlerin kıyaslanması Tablo 25 ve 26’da verilmektedir.

Tablo 25. ÇDR ve ZS yöntemlerinde test kümesi verileri için MAPE değerlerin kıyaslanması

Yıllar	Gerçek (KWH)	Tahmin (KWH)		APE %	
		ZS	ÇDR	ZS	ÇDR
2003	128663000000		129246226570.21		0.45%
2004	138559000000		137987570298.16		0.41%
2005	145075000000		147844288810.97		1.91%
2006	156716000000	155549978065.58	158990201360.85	0.74%	1.45%
2007	164594000000	165849075131.32	171675450654.99	0.76%	4.30%
2008	174718000000	176851645938.35	181430961908.68	1.22%	3.84%
2009	182739000000	186751924506.83	190145016358.52	2.20%	4.05%
2010	196201000000	196254279902.45	195559499236.79	0.03%	0.33%
2011	199787000000	206476160542.95	209376451577.85	3.35%	4.80%
2012	218915000000	215074981890.65	213706233286.85	1.75%	2.38%
2013	230972000000	227481410408.44	232422857907.66	1.51%	0.63%
2014	241921000000	236443095543.68	241373535956.34	2.26%	0.23%
MAPE				1.54%	2.07%

Tablo 26. Sebep sonuç yönteminde test kümesi verileri için APE ve MAPE değerleri

YSA			APE %
Yıllar	Gerçek(KWH)	Tahmin	
1979	20692000000	20363793904.74	1.59%
1982	25662000000	25031679746.75	2.46%
1985	35486000000	35855032446.86	1.04%
1987	41347000000	42358465092.52	2.45%
1990	53034000000	51874575878.42	2.19%
1993	66501000000	67887000384.65	2.08%
1996	79649000000	77197422740.91	3.08%
1998	88295000000	89744969007.34	1.64%
2004	138559000000	138217014832.79	0.25%
2007	164594000000	166543575121.95	1.18%
2011	199787000000	204482211882.29	2.35%
2013	230972000000	229112009154.20	0.81%
MAPE			1.76%

Tablo 25 ve 26’da görüldüğü gibi oluşturulan üç farklı modelin tahmin sonuçları, test kümesi için hesaplanan MAPE değerlerine göre incelendiğinde, YSA zaman serisi modelinin daha başarılı sonuçlar verdiği görülmektedir.

YSA zaman serisi, YSA sebep sonuç ve çoklu doğrusal regresyon modellerinin test kümesi için MAPE değerlerinin sırasıyla %1.54, %1.76 ve %2.07 olması YSA zaman serisi yönteminin diğer yöntemlere göre daha iyi sonuç verdiğini göstermektedir.

Tablo 27 ve 28’de tüm modellerden elde edilen tahmin değerleri, İran Enerji Bakanlığı (EB) tarafından tahmin edilen değerler ile karşılaştırılmış ve mutlak yüzde hataları ve ortalama mutlak yüzde hataları kıyaslanmıştır.

İran Enerji Bakanlığı’nın gelecek yıllara ait tahmin değerlerinin, hangi yöntemlerle elde edildiği ve ne kadar başarılı olduğu bilinmemektedir.

Bununla beraber tahmin çalışmaları gelecekteki yatırımların yönlendirilmesinde ve elektrik enerjisi tüketim politikalarının belirlenmesinde çok önemli bir yere sahip olduğundan farklı tahmin çalışmalarının da göz önünde bulundurulması gereklidir.

Tablo 27 ve 28’de YSA zaman serisi modelinin ve düşük senaryo (DS), beklenen senaryo (BS) ve yüksek senaryolar (YS) için, YSA sebep sonuç ve çoklu doğrusal regresyon modellerinin tahmin sonuçları ile İran enerji bakanlığı tahmin değerleri ve birbirleriyle karşılaştırılmaları görülmektedir.

Tablo 27. Enerji Bakanlığı'nın değerleri ile kurulan modellerin sonuçlarının karşılaştırılması

Yıllar	EB (GWH)	YSA (sebep-sonuç)			Zaman serisi	Regresyon		
		DS	BS	YS		DS	BS	YS
2015	253058	253220	265296	290211	245464	24803	267403	301499
2016	270522	264089	294114	384282	251029	25544	298268	387545
2017	295408	276708	329400	536585	254249	26426	333802	505009
2018	312188	293402	372743	720098	257013	27431	374866	668669
2019	350963	319194	425033	843589	258965	28548	422513	901982
2020	381953	364267	486195	873860	260420	29770	478032	1243385
2021	415292	446024	554855	875549	261472	31094	543020	1758213

Tablo 28. Enerji Bakanlığı'nın değerleri ile kurulan modellerin APE ve MAPE kıyaslanması

Yıllar	YSA (sebep-sonuç)			Zaman serisi	Regresyon		
	DS	BS	YS		DS	BS	YS
2015	0.06%	4.84%	14.68%	3.00%	1.99%	5.67%	19.14%
2016	2.38%	8.72%	42.05%	7.21%	5.57%	10.26%	43.26%
2017	6.33%	11.51%	81.64%	13.93%	10.54%	13.00%	70.95%
2018	6.02%	19.40%	130.66%	17.67%	12.13%	20.08%	114.19%
2019	9.05%	21.10%	140.36%	26.21%	18.66%	20.39%	157.00%
2020	4.63%	27.29%	128.79%	31.82%	22.06%	25.15%	225.53%
2021	7.40%	33.61%	110.83%	37.04%	25.13%	30.76%	323.37%
MAPE	5.12%	18.07%	92.72%	19.55%	13.73%	17.90%	136.21%

Tablo 27 ve 28'de, oluşturulan üç farklı modelin 2015-2021 yılları arasındaki net elektrik enerji tüketimi için tahmin sonuçları, İran Enerji Bakanlığı tahmin değerleri ile karşılaştırıldığında düşük, beklenen ve yüksek senaryolarda YSA sebep sonuç modelinin çoklu doğrusal regresyon modelinden daha iyi sonuçlar verdiği görülmektedir.

YSA sebep sonuç, YSA zaman serisi ve çoklu doğrusal regresyon modellerinin gelecek 7 yıllık net elektrik enerji tüketimi tahmin değerleri, İran Enerji Bakanlığı tahmin değerleri ile karşılaştırıldığında düşük senaryo için MAPE değerlerinin sırasıyla %5.12, %19.55 ve %13.73 olması YSA sebep sonuç yönteminin diğer yöntemlere göre daha iyi sonuç verdiğini göstermektedir.

İran Enerji Bakanlığı'nın 2015 yıllı net elektrik enerjisi tüketimi tahmini 253058 GWH iken çalışmamızda YSA modeli ile yapılan tahmin 253220 GWH'dir. Bu tahmin değerleri, gerçekleşen değer 251870 GWH ile kıyaslandığında önemli bir fark olmadığı

anlaşılmaktadır. Bu sonuçlar ışığında YSA'nın elektrik enerji tüketimi tahmininde etkin bir şekilde kullanılabileceği görülmektedir.

3.2. Öneriler

Yapay sinir ağları geleceği tahmin etmede etkili bir yöntem olarak kullanılabilir. Tahmin doğruluğu modellerin sorunsuz olması koşuluyla verilerdeki hata miktarıyla ilgilidir. Uzak geleceğin tahmini için YSA sebep sonuç modelleri girdi parametrelerinin gelecekteki değerlerinin doğru belirlenmesi durumunda daha doğru tahminler yapabilirken YSA zaman serisi modelleri yakın gelecekteki verilerin tutarlı olması durumunda daha doğru tahminlerde bulunabilmektedir. Sürenin uzaması ve verilerin değişkenlik göstermesi YSA zaman serisi modellerinin tahmin doğruluğunu azaltır. Uzak geleceğin tahmini için YSA sebep sonuç modelleri kullanılmalıdır. Yakın geleceğin tahminlerinde YSA zaman serisi modelleri kullanılabilir.

4. KAYNAKLAR

- Akdağ, Y., 2010. Vadeli İşlem ve Opsiyon Borsası'nda TL Dolar Vadeli İşlem Sözleşmelerinin Gün Sonu Uzlaşma Fiyatının Yapay Sinir Ağları ile Tahmini, Yüksek Lisans Tezi, Marmara Üniversitesi, Bankacılık ve Sigortacılık Enstitüsü, İstanbul.
- Alan, E., 2013. Yapay Sinir Ağları Yaklaşımı ile Cüruflarda Fosfor Kapasitelerinin İncelenmesi, Yüksek Lisans Tezi, İstanbul Teknik Üniversitesi, Fen Bilimleri Enstitüsü, İstanbul.
- Aydın, D., 2012. Yapay Sinir Ağları Yardımı ile Talep Tahmin Analizi ve Deniz Taşımacılığı Sektöründe Bir Uygulama, Yüksek Lisans Tezi, Marmara Üniversitesi Sosyal Bilimleri Enstitüsü, İstanbul.
- Alfauhid, A., S., Elsayed, M., A. ve Mahmoud, M., S., 1997. Cascaded Artificial Neural Networks for Short-Term Load Forecasting, IEEE Transactions on Power Systems, 12, 4, 1524-1529.
- Almamun, M. ve Nagasaka, K., 2004. Artificial Neural Networks Applied to Long-term Electricity Demand Forecasting, Fourth International Conference on Hybrid Intelligent Systems, Aralık, Japan, Bildiriler Kitabı: 204-209.
- Altınışık, A., 2012. Toprak İşlemede Traktör Çeki Performansının Yapay Sinir Ağları ile Analizi, Doktora Tezi, Selçuk Üniversitesi, Fen Bilimleri Enstitüsü, Konya.
- Anderson, D. ve McNeill, G., 1992. Artificial Neural Networks Technology, Rome Laboratory, ELIN: A011, New York.
- Asare Bediako, B., Kling, W., L. ve Riberio, P., F., 2013. Day-Ahead Residential Load Forecasting with Artificial Neural Networks Using Smart Meter Data, Power Tech, Haziran, Grenoble, Bildiriler Kitabı: 1-6.
- Ataseven, B., 2007. Satış Öngörü Modellemesi Tekniği Olarak Yapay Sinir Ağlarının Kullanımı: Petkim'de Uygulanması, Yüksek Lisans Tezi, Celal Bayar Üniversitesi, Sosyal Bilimleri Enstitüsü, Manisa.
- Atasoy, S., 2010. Yapay Sinir Ağları ve Sinirsel Bulanık Ağlar ile İnsan Kaynaklarında Performans Yönetimi Modellenmesi, Yüksek Lisans Tezi, Yıldız Teknik Üniversitesi, Fen Bilimleri Enstitüsü, İstanbul.
- Azadeh, A., Ghaderi, S., F., Tarverdian, S. ve Saberi, M., 2007. Integration of Artificial Neural Networks and Genetic Algorithm to Predict Electrical Energy Consumption, Applied Mathematics and Computation, 186, 2, 1731-1741.

- Azadeh, A., Ghaderi, S., F. ve Sohrabkhani, S., 2008. Annual Electricity Consumption Forecasting by Neural Network in High Energy Consuming Industrial Sectors, Energy Conversion and Management, 49, 8, 2272-2278.
- Bahadır, İ., 2008. Bayes Teoremi ve Yapay Sinir Ağları Modelleriyle Borsa Gelecek Değer Tahmini Uygulaması, Yüksek Lisans Tezi, TOBB Ekonomi Ve Teknoloji Üniversitesi, Fen Bilimleri Enstitüsü, Ankara.
- Bahadır, Y., 2013. Cam Elyaf Katkılı Cephe Kaplama Elemanlarına Yönelik Teklif Fiyatı Tahmininde Yapay Sinir Ağlarının (YSA) Kullanılması, Yüksek Lisans Tezi, İstanbul Teknik Üniversitesi, Fen Bilimleri Enstitüsü, İstanbul.
- Barzamini, R., Menhaj, M., B., Kamalvand, SH. ve Tajbakhsh, A., 2005. Short Term Load Forecasting of Iran National Power System Using Artificial Neural Network Generation Two, Power Tech IEEE Russia, Haziran, Petersburg, Bildiriler Kitabı: 1-5.
- Baş, N., 2006. Yapay Sinir Ağları Yaklaşımı ve Bir Uygulama, Yüksek Lisans Tezi, Mimar Sinan Güzel Sanatlar Üniversitesi, Fen Bilimleri Enstitüsü, İstanbul.
- Bayır, F., 2006. Yapay Sinir Ağları ve Tahmin Modellemesi Üzerine Bir Uygulama, Yüksek Lisans Tezi, İstanbul Üniversitesi, Sosyal Bilimleri Enstitüsü, İstanbul.
- Bilgili, M., Şahin, B., Yaşar, A. ve Şişmek, E., 2012. Electric Energy Demands of Turkey in Residential and Industrial Sectors, Renewable and Sustainable Energy Reviews, 16, 404-414.
- Bölükbaş, U., 2010. Regresyon ve Yapay Sinir Ağı ile Finans Sektörü Risk Yönetimi, Yüksek Lisans Tezi, Sakarya Üniversitesi, Fen Bilimleri Enstitüsü, Sakarya.
- Buhari, M. ve Adamu, S., S., 2012. Short-Term Load Forecasting Using Artificial Neural Network, Proceeding of the International Multi Conference of Engineers and Computer Scientist, Hong Kong, Bildiriler Kitabı: 14-16.
- Çilli, M., 2007. İnsan Hareketinin Modellenmesi ve Benzeşiminde Temel Bileşenler Analizi Yönteminin Kullanılması, Doktora Tezi, Hacettepe Üniversitesi, Sağlık Bilimleri Enstitüsü, Ankara.
- Clarkson, T., 1999. Applications of Neural Networks in Telecommunications, King's College London. Company, Boston.
- Çuhadar, M. ve Kayacan, C., 2005. Yapay Sinir Ağları Kullanılarak Konaklama İşletmelerinde Doluluk Oranı Tahmini: Türkiye'deki Konaklama İşletmeleri Üzerine Bir Deneme, Anatolia: Turizm Araştırmaları Dergisi, Anatolia, 16, 1, 24-30.
- Deveci, M., 2012. Yapay Sinir Ağları ve Bekleme Süresinin Tahmininde Kullanılması, Yüksek Lisans Tezi, Gazi Üniversitesi, Sosyal Bilimleri Enstitüsü, Ankara.

- Dilaver, Z. ve Lester, C., H., 2011. Industrial Electricity Demand for Turkey: A Structural Time Series Analysis, Energy Economics, 33, 426-436.
- Demuth, H., Beale, M. ve Hagan, M., 2008. Neural Network. Toolbox 6 User's Guide, Natick, MA: The Math Works.
- Efe, Ö. ve Kaynak, O., 2006. Yapay Sinir Ağları ve Uygulamaları, İstanbul: Boğaziçi Üniversitesi Yayınları, Ankara.
- Eke, İ., 2011. Diferansiyel Evrim Algoritması Destekli Yapay Sinir Ağı ile Orta Dönem Yük Tahmini, International Journal of Research and Development, 3, 28-32.
- Esfahani, L., H., Alfonso, T., R., Jensen, A. ve Mckee, M., 2015. Assessment of Surface Soil Moisture Using High-Resolution Multi-Spectral Imagery and Artificial Neural Networks, Remote Sens, 7, 2627-2646.
- Ekonomou, L., 2010. Greek Long-Term Energy Consumption Prediction Using Artificial Neural Networks, Energy, 35, 512-517.
- Elmas, Ç., 2003. Yapay Sinir Ağları, Seçkin Yayıncılık, Ankara.
- Elmas, Ç., 2011. Yapay Zeka Uygulamaları, 2. Baskı, Seçkin Yayıncılık, Ankara.
- Ergezer, H., Dikmen, M. ve Özdemir, E., 2003. Yapay Sinir Ağları ve Tanıma Sistemleri, Pivolka, 2, 6, 14-17.
- Ergin, Z., 2012. Temel Bileşenler Faktör Analizine Dayalı Yapay Sinir Ağları Modelleri ile İMKB 100 Endeks Getirilerinin Tahmini, Yüksek Lisans Tezi, Çukurova Üniversitesi, Sosyal Bilimleri Enstitüsü, Adana.
- Eroğlu, N., 2006. Yapay Sinir Ağı Tabanlı Doğrusallaştırma Birimi Tasarımı, Yüksek Lisans Tezi, Erciyes Üniversitesi, Fen Bilimleri Enstitüsü, Kayseri.
- Ertunç, H., M., 2006. Prediction of the Pool Boiling Critical Heat Flux Using Artificial Neural Network, IEEE Transactions on Components and Packaging Technologies, 29, 4, 770-777.
- Fan, S. ve Hyndman, R., J., 2012. Short-Term Load Forecasting Based On a Semi-Parametric Additive Model, IEEE Transactions On Power Systems, 27, 134- 141.
- Fausett, L., 1994. Fundamentals of Neural Networks, Prentice-Hall, New Jersey.
- Gangam, H. ve Ünver, Ö., 2008. Temel İstatistik Yöntemleri, 5. Baskı, Seçkin Yayıncılık, Ankara.
- Geçkil, M., 2014. Çoklu Doğrusal Regresyon (MLR) Metoduyla Ni-Mn-Ga Esaslı Şekil Hafızalı Alaşımlara Eşlik Eden Ms, Mf, As, Af, ve As-Ms Sıcaklıklarının Belirlenmesi, Yüksek Lisans Tezi, Kahramanmaraş Sütçü İmam Üniversitesi, Fen Bilimleri Enstitüsü, Kahramanmaraş.

- Ghanbari, A., Naghavi, A., Ghaderi, S., F. ve Sabaghian, M., 2009. Artificial Neural Networks and Egression Approaches Comparison for Forecasting Iran's Annual Electricity Load, International Conference on Power Engineering, Energy and Electrical Drives, Mart, Lisbon, Bildiriler Kitabı: 675- 679.
- Geem, Z., W. ve Roper, W., E., 2009. Energy Demand Estimation of South Korea Using Artificial Neural Network, Energy Policy, 37, 4049-4054.
- Graves, A. ve Schmidhuber, J., 2008. Offline Handwriting Recognition with Multidimensional Recurrent Neural Networks, Advances in Neural Information Processing Systems (NIPS Conference), Vancouver, Bildiriler Kitabı: 545-552.
- Güngör, E., 2007. Yapay Sinir Ağları Yardımı ile Makine Arızalarının Önceden Tahmin Edilmesi, Yüksek Lisans Tezi, Kocaeli Üniversitesi, Sosyal Bilimleri Enstitüsü, Kocaeli.
- Gürsoy, A., 2012. Yapay Sinir Ağları Yaklaşımıyla Lastik Kalıbı Maliyetlerini Tahmin Edilmesi, Yüksek Lisans Tezi, Kocaeli Üniversitesi, Fen Bilimleri Enstitüsü, Kocaeli.
- Hagan, M., T., Demuth H., B. ve Beale M., 1996. Neural Network Design, PWS Publishing.
- Hahn, H., Nieberg, S., M. ve Pickl, S., 2009. Electric Load Forecasting Methods: Tools for Decision Making, European Journal of Operational Research, 199, 902- 907.
- Hamzaçebi, C. ve Kutay, F., 2004. Yapay Sinir Ağları ile Türkiye Elektrik Enerjisi Tüketiminin 2010 Yılına Kadar Tahmini, Ankara, Gazi Üniversitesi. Mühendislik Mimarlık Fakültesi Dergisi, 19, 227-233.
- Hamzaçebi, C., 2007. Forecasting of Turkey's Net Electricity Energy Consumption on Sectoral Bases, Energy Policy, 35, 2009-2016.
- Hamzaçebi, C., 2011. Yapay Sinir Ağları: Tahmin Amaçlı Kullanımı Matlab ve Neurosolutions Uygulamalı, Ekin Yayınevi, Trabzon.
- Hamzaoğlu, S., 2013. Çoklu Regresyon Yöntemlerinde Güç Analizi, Yüksek Lisans Tezi, Ondokuz Mayıs Üniversitesi, Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, Samsun.
- Haykin, S., 1994. Neural Network, A Comprehensive Foundation, Macmillan College Publishing Company, New York.
- Helvacı, Ö., 2007. Santrifüj Pompalarda Yapay Sinir Ağı Uygulamaları, Yüksek Lisans Tezi, Eskişehir Osmangazi Üniversitesi, Fen Bilimleri Enstitüsü, Eskişehir.
- Hsu, C., C. ve Chen, C., Y., 2003. Regional Load Forecasting in Taiwan—Applications of Artificial Neural Networks, Energy Conversion and Management, 44, 1941–1949.

- Horat, B., 2014. Genetik Algoritma ile Ankara İlinde Mobese (Kent Güvenlik Yönetim Sistemi) Yerleştirme Optimizasyonu, Yüksek Lisans Tezi, Gazi Üniversitesi, Fen Bilimleri Enstitüsü, Ankara.
- Kankal, M., Akpınar, A., Kömürcü, M. ve Özaşın T., Ş., 2011. Modeling and Forecasting of Turkey's Energy Consumption Using Socio-Economic and Demographic Variables, Applied Energy, 88, 1927-1939.
- Kavaklıoğlu, K., Ceylan, H., Öztürk, H., K. ve Canyurt, O., E., 2009. Modeling and Prediction of Turkey's Electricity Consumption Using Artificial Neural Networks, Energy Conversion and Management, 50, 2719-2727.
- Kaya, İ., Oktay, S. ve Engin, O., 2005. Kalite Kontrol Problemlerinin Çözümünde Yapay Sinir Ağlarının Kullanımı, Erciyes Üniversitesi Fen Bilimleri Enstitüsü Dergisi, 21, 92-107.
- Kaya, T., 2013. Yapay Sinir Ağları Yöntemi ile Heyelanlarda Stabilité Analizi, Yüksek Lisans Tezi, Karadeniz Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Trabzon.
- Kaysal, K., Hocaoglu, F., O. ve Kaysal, A., 2015. Yük Tahmini İçin Hibrit (YSA ve Regresyon) Model, Academic Platform Journal of Engineering and Science, 32, 33-39.
- Kialashaki, A. ve Reisel, J., R., 2014. Development and Validation of Artificial Neural Network Models of The Energy Demand in The Industrial Sector of The United States, Energy, 76, 749-760.
- Kröse, B. ve Van Der Smagt, P., 1996. An Introduction to Neural Networks, Eighth Edition, The University of Amsterdam.
- Kutlar, A., 2007. Ekonometriye Giriş, 9786053950325, Nobel Basım Evi, Ankara.
- Mandal, J., K. ve Sinha, A., K., 1995. Application of Recurrent Neural Network for Short Term Load Forecasting in Electric Power System, Neural Networks, IEEE International Conference on (Volume:5), Aralık, Perth, Bildiriler Kitabı: 2694-2698.
- Marin, F., J., Garcia Lagos, F. ve Sandoval, F., 2002. Global Model for Short-term Load Forecasting Using Artificial Neural Networks, Generation Transmission & Distribution, 149, 2, 121-125.
- Mehrotra, K., Mohan, C., K. ve Ranka, S., 1997. Elements of Artificial Neural Networks, A Bradford Book, London.
- Lee, K., Y., Cha, Y., T. Ve Park, J., H., 1992. Short-Term Load Forecasting Using an Artificial Neural Network, Transactions on Power Systems, IEEE Transactions on Power Systems, 7, 1, 124-132.

- Moharari, N. ve Debs, A., 1993. An Artificial Neural Network Based Short Term Load Forecasting with Special Tuning for Weekends and Seasonal Changes, Neural Networks to Power Systems, Neural Networks to Power Systems, Proceedings of the Second International Forum on Applications of, Nisan, Yokohama, Japan, Bildiriler Kitabı: 279-283.
- Mete, T., 2008. Kesikli Bir Biyoreaktörde Yapay Sinir Ağlarının Kullanımı, Yüksek Lisans Tezi, Ankara Üniversitesi, Fen Bilimleri Enstitüsü, Ankara.
- Moturi, C., A. ve Kioko, F., K., 2013. Use of Artificial Neural Networks for Short-Term Electricity Load Forecasting of Kenya National Grid Power System, International Journal of Computer Application, 63, 2, 25-30.
- Orhunbilge, N., 1996. Uygulamalı Regresyon ve Korelasyon Analizi, Avcıol Basım Yayın, İstanbul.
- Özcan, B., 2007. Yapay Sinir Ağı Yaklaşımıyla, Peçete Makinesi İmalatı Yapan İşletmede Makine İşleme Sürelerinin Tahmin Edilmesi, Yüksek Lisans Tezi, Kocaeli Üniversitesi, Fen Bilimleri Enstitüsü, Kocaeli.
- Okutan, C., 2014. Borsa İstanbul Şirketlerinin Hisse Senedi Getirilerinin Yapay Sinir Ağları ve Çoklu Regresyon Yöntemleri Kullanarak Analizi, Yüksek Lisans Tezi, Kocaeli Üniversitesi, Fen Bilimleri Enstitüsü, Kocaeli.
- Özşahin, Ş., 2013. Optimization of Process Parameters in Oriented Strand Board Manufacturing with Artificial Neural Network Analysis, European Journal of Wood and Wood Products, 71, 6, 769-777.
- Öztemel, E., 2006. Yapay Sinir Ağları, 2. Baskı, Papatya Yayıncılık, İstanbul.
- Öztemel, E., 2012. Yapay Sinir Ağları, 3. Baskı, Papatya Yayıncılık, İstanbul.
- Padmakumari, K., Mohandas, K., P. ve Thiruvengadam, S., 1999. Long Term Distribution Demand Forecasting Using Neuro Fuzzy Computations, In. Jo. of Electrical Power and Energy Systems, 21, 5, 315-322.
- Pao, H., T., 2006. Comparing Linear and Nonlinear Forecasts for Taiwan's Electricity consumption, Energy, 31, 12, 2129-2141.
- Park, D., C., Elsharkawi, M., A., Marks, R., J., Atlas, L., E. ve Damborg, M., J., 1991. Electric Load Forecasting Using an Artificial Neural Network, IEEE Transactions on Power Systems, 6, 2, 442-449.
- Parlos, A., G., Oufi, E., Muthusami, J., Patton A., D. ve Atiya A., F., 1996. Development of an Intelligent Long-Term Electric Load Forecasting System, Intelligent System Applications to Power System International Conference, 28 Ocak, Orlando, Bildiriler Kitabı: 288-292.

- Romera, E., G., Jaramillo Moran, M., A. ve Carmona Fernandez, D., 2007. Forecasting of The Electric Energy Demand Trend and Monthly Fluctuation with Neural Networks, Computers and Industrial Engineering, 52, 3, 336–343.
- Russell, B., 2011. A Simple Principal Component Analysis Example.
- Sađırođlu, Ő., BeŐdok, E. ve Erler, M., 2003. Mühendislikte Yapay Zeka Uygulamaları-I Yapay Sinir Ağları, Ufuk Kitap Kırtasiye, Kayseri.
- Ően, G., Akyol, E. ve Fırat, M., 2007. SıvılaŐmaya KarŐı Güvenlik Katsayısının Yapay Sinir Ağları ile Tahmin Edilmesi: Denizli-GümüŐler Örneđi, S.Ü. Müh.-Mim. Fak. Dergi, 23, 1-2.
- Sözen, A., Arcaklıođlu, E., Özalp, M. ve Kanıt, E., G., 2004. Use of Artificial Neural Networks for Mapping of Solar Potential in Turkey, Applied Energy, 77, 3, 273–286.
- Sözen, A., Arcaklıođlu, E. ve Özkaymak, M., 2005. Turkey's Net Energy Consumption. Applied Energy, 81, 2, 209–221.
- Sözen A. ve Arcaklıođlu E., 2007. Prediction of Net Energy Consumption Based on Economic Indicators (GNP and GDP) in Turkey, Energy Policy, 35, 10, 4981-4992.
- Sütçüler, E., 2006. Gerçek Zamanlı Video Görüntülerinden Yüz Bulma ve Tanıma Sistemi, Yüksek Lisans Tezi, Yıldız Teknik Üniversitesi, Fen Bilimleri Enstitüsü, İstanbul.
- Sarı, M., 2016. Yapay Sinir Ağları ve Bir Otomotiv Firmasında SatıŐ Talep Tahmini Uygulaması, Yüksek Lisans Tezi, Sakarya Üniversitesi, Fen Bilimleri Enstitüsü, Sakarya.
- TektaŐ, M., AkbaŐ, A. ve Topuz, V., 2002. Yapay Zeka Tekniklerinin Trafik Kontrolünde Kullanılması Üzerine Bir İnceleme, Uluslararası Trafik ve Yol Güvenliđi Kongresi, Ankara, Bildiriler Kitabı: 551-559.
- Temür, G., 2013. Yapay Sinir Ağlarının Otomatik Olarak FPGA Çipine Uygulanması İçin Denetleyici Tasarım Aracı, Yüksek Lisans Tezi, Düzce Üniversitesi, Fen Bilimleri Enstitüsü, Düzce.
- Toker, A., C. ve Korkmaz, O., 2011. Türkiye Kısa Süreli Elektrik Talebinin Saatlik Olarak Tahmin Edilmesi, Elektrik Tesisat Ulusal Kongresi, İstanbul, Bildiriler Kitabı: 23-29.
- Tolon, M. ve Tosunođlu, N.,G., 2008. Tüketici Tatmini Verilerinin Analizi: Yapay Sinir Ağları Ve Regresyon Analizi KarŐılaŐtırılması, Gazi Üniversitesi İktisadi İdari Bilimleri Fakültesi Dergisi, 10/2, 247-259.
- URL-1, <http://www.denkbilgi.com/elektrigin-hayatimizdaki-onemi-nedir.html>, 9 Haziran 2015.
- URL-2, <http://www.nytimes.com/2010/10/10/science/10google.html>, 1 Mayıs, 2016.

- URL-3, <http://research.microsoft.com/en-us/people/jamiesh>, 9 Haziran 2015.
- URL-4, <http://www.bbc.co.uk/news/technology-35420579>, 1 Mayıs 2016.
- URL-5, <http://www.kurzweilai.net/how-bio-inspired-deep-learning-keeps-winning-competitions>, 1 Mayıs 2016.
- URL-6, <http://data.worldbank.org>, 5 Nisan 2015.
- URL-7, <http://amar.tavanir.org.ir/pages/report/index90.php>, 10 Kasım 2014.
- URL-8, <http://www.amar.org.ir>, 10 Kasım 2014.
- URL-9, <http://financialexamhelp123.com/durbin-watson-statistic-test>, 9 Haziran 2015.
- Uzlu, E., Kankal, M., Akpınar, A. ve Dede, T., 2014. Estimates of Energy Consumption in Turkey Using Neural Networks with The Teaching learning-Based Optimization Algorithm, *Energy*, 75, 295-303.
- Var, H. ve Türkay, B., E., 2014. Yapay Sinir Ağları Kullanılarak Kısa Dönem Elektrik Yükü Tahmini, Eleco 2014 Elektrik – Elektronik – Bilgisayar ve Biyomedikal Mühendisliği Sempozyumu, Kasım, Bursa, Bildiriler Kitabı: 23-27.
- Voss, L., D., Salama, M., M., A. ve Reeve, J., 1995. A Practical Approach to Electric Load Forecasting Using Artificial Neural Networks with Corrective Filtering, *Electrical and Computer Engineering*, Eylül, Montreal, Bildiriler Kitabı: 370-373.
- Yakut, E., 2012. Veri Madenciliği Tekniklerinden C5.0 Algoritması ve Destek Vektör Makineleri ile Yapay Sinir Ağlarının Sınıflandırma Başarılarının Karşılaştırılması: İmalat Sektöründe Bir Uygulama, Doktora Tezi, Atatürk Üniversitesi, Sosyal Bilimleri Enstitüsü, Erzurum.
- Yalçınöz, T., Herdem, S. ve Eminoğlu, U., 2002. Yapay Sinir Ağları ile Niğde Bölgesinin Elektrik Yük Tahmini, Elektrik – Elektronik - Bilgisayar Mühendisliği Sempozyumu, Bursa, Bildiriler Kitabı: 25-29.
- Yiğit, P., 2011. Yapay Sinir Ağları ve Kredi Taleplerinin Değerlendirilmesi Üzerine Bir Uygulama, Yüksek Lisans Tezi, İstanbul Üniversitesi, Sosyal Bilimleri Enstitüsü, İstanbul.
- Yıldırım, N., 2010. "En Küçük Kareler, Ridge Regresyon ve Robust Regresyon Yöntemlerinde Analiz Sonuçlarına Aykırı Değerlerin Etkilerinin Belirlenmesi", Yüksek Lisans Tezi, Çukurova Üniversitesi, Fen Bilimleri Enstitüsü, Adana.
- Yücesoy, M., 2011. Temizlik Kağıtları Sektöründe Yapay Sinir Ağları ile Talep Tahmini, Yüksek Lisans Tezi, İstanbul Teknik Üniversitesi, Fen Bilimleri Enstitüsü, İstanbul.

- Yang, J., Pickett, M., Li, X., Ohlberg, D., Stewart, D. ve Williams, R., 2008. Memristive Switching Mechanism for Metal/Oxide/Metal Nanodevices, Nature Nanotechnology, 3, 429-433.
- Zahedi, G., Azizi, S., Bahadori, A., Elkamel, A. ve Wan Alawi, S., R., 2013. Electricity Demand Estimation Using an Adaptive Neuro-Fuzzy Network: A Case Study from The Ontario Province-Canada, Energy, 49, 323-328.
- Zhang, G., Patuwo, B., E. ve Hu, M., Y., 1998. Forecasting with Artificial Neural Networks: The State of The Art, International Journal of Forecasting, 14, 1, 35-62.
- Zhang, S., Lian, J., Zhao, Z., Xu, H. ve Liu, J., 2008. Grouping Model Application on Artificial Neural Networks for Short-term Load Forecasting, World Congress on Intelligent Control and Automation, Haziran, Chongqing China, Bildiriler Kitabı: 6203-6206.



ÖZGEÇMİŞ

16.09.1988 yılında İran' da doğdu. İlk, orta ve lise öğrenimini İran' da tamamladı. 2008 yılında Azad Zanjan Üniversitesi, Mühendislik Fakültesi, Endüstri Mühendisliği Bölümü'ne kayıt yaptırdı. 2011 yılında bu bölümden Endüstri Mühendisi unvanı ile mezun oldu. 2012 yılında KTÜ, Fen Bilimleri Enstitüsü, Endüstri Mühendisliği Anabilim Dalı, Endüstri Mühendisliği Dalında yüksek lisans eğitimini başladı.

