

İSTANBUL TEKNİK ÜNİVERSİTESİ ★ ENERJİ ENSTİTÜSÜ

**YAPAY SİNİR AĞLARIYLA KONYA BÖLGESİNDE KULLANICI DOĞAL
GAZ TÜKETİM ÖNGÖRÜSÜ**

YÜKSEK LİSANS TEZİ

Burcu AKIN

Enerji Bilim ve Teknoloji Anabilim Dalı

Enerji Bilim ve Teknoloji Programı

MAYIS 2017

İSTANBUL TEKNİK ÜNİVERSİTESİ ★ ENERJİ ENSTİTÜSÜ

**YAPAY SİNİR AĞLARIYLA KONYA BÖLGESİNDE KULLANICI DOĞAL
GAZ TÜKETİM ÖNGÖRÜSÜ**

YÜKSEK LİSANS TEZİ

**Burcu AKIN
(301121055)**

Enerji Bilim ve Teknoloji Anabilim Dalı

Enerji Bilim ve Teknoloji Programı

Tez Danışmanı: Yrd. Doç. Dr. Burak BARUTÇU

MAYIS 2017

İTÜ, Enerji Enstitüsü'nün 301121055 numaralı Yüksek Lisans Öğrencisi Burcu AKIN, ilgili yönetmeliklerin belirlediği gerekli tüm şartları yerine getirdikten sonra hazırladığı “YAPAY SİNİR AĞLARIYLA KONYA BÖLGESİNDE KULLANICI DOĞAL GAZ TÜKETİM ÖNGÖRÜSÜ” başlıklı tezini aşağıda imzaları olan jüri önünde başarı ile sunmuştur.

Tez Danışmanı : **Yrd. Doç. Dr. Burak BARUTÇU**
İstanbul Teknik Üniversitesi

Jüri Üyeleri : **Prof. Dr. Tülay Yıldırım**
Yıldız Teknik Üniversitesi

Doç. Dr. Ömer İnanç Türeyen
İstanbul Teknik Üniversitesi

Teslim Tarihi : **5 Mayıs 2017**
Savunma Tarihi : **7 Mayıs 2017**

ÖNSÖZ

Doğal gaz ticareti yaparken önemini daha da iyi anladığım talep tahmini konusunu yapay sınır ağlarıyla bir araya getirmemi sağlayan bu tez çalışması ile yapay sınır ağları (YSA) kullanılarak Konya bölgesine ait günlük doğal gaz tüketim tahmini yapılmıştır. Bu vesileyle, çalışmada kullanılan doğal gaz tüketim ve abone sayısı (bbs) verilerini temin ettiğim Enerya Konya Gaz Dağıtım A.Ş.'ye ve tüm Enerya ailesine ilgisi ve desteği için teşekkürlerimi sunuyorum.

Uzayan tez yazma sürecimin başından itibaren hiçbir zaman yardım ve desteğini esirgemeyen, değerli hocam ve tez danışmanım sayın Yrd. Doç. Burak Barutçu'ya, yönlendirmeleri ve bana olan inancından dolayı teşekkür ediyorum.

Tüm öğrenim hayatım boyunca, maddi manevi desteğini esirgemeyen, attığım her adımın arkasında olan, bana olan güvenlerinden hiçbir zaman şüphe etmediğim canım aileme, iş ve okul hayatını birlikte yürütebilmem için her türlü desteği ve yardımı veren başta Can İshakoğlu olmak üzere, değerli iş arkadaşlarıma, dostlarıma sabır ve anlayışları için çok teşekkür ediyorum. Bu uzun süreci tamamlayabilmem adına elinden gelen her şeyi yapan değerli arkadaşım Mehmet Şimşek'e ve bu süreci hızlandırmadaki önemi yadsınamayacak olan Toshy'ye de ayrıca teşekkürlerimi sunuyorum.

Mayıs 2017

Burcu AKIN
(Kimya Mühendisi)

İÇİNDEKİLER

Sayfa

ÖNSÖZ.....	v
İÇİNDEKİLER	vii
KISALTMALAR	ix
SEMBOLLER	xi
ÇİZELGE LİSTESİ.....	xiii
ŞEKİL LİSTESİ.....	xiv
ÖZET.....	xvii
SUMMARY	xix
1. GİRİŞ	1
2. DOĞAL GAZ PİYASASI.....	5
2.1 Enerji Kaynağı Olarak Doğal Gaz.....	5
2.2 Küresel Doğal Gaz Sektörünün Görünümü	6
2.2.1 Küresel doğal gaz rezervleri ve üretimi	7
2.2.2 Küresel doğal gaz tüketimi	8
2.3 Türkiye Doğal Gaz Sektörünün Görünümü	8
2.3.1 Türkiye doğal gaz rezervleri ve üretimi	9
2.3.2 Türkiye doğal gaz tüketimi	9
2.4 Türkiye Doğal Gaz Piyasasının Yapısı	10
2.4.1 Üretim	11
2.4.2 İthalat	13
2.4.3 İhracat.....	15
2.4.4 Toptan satış	16
2.4.5 İletim	17
2.4.6 Dağıtım.....	18
2.4.7 Depolama	19
3. TALEP TAHMİN MODELLERİ.....	21
3.1 Talep Tahmini	21
3.2 Talep Tahmin Yöntemleri	22
3.2.1 Regresyon analizi	23
3.2.2 Zaman serisi analizine dayanan yöntemler	25
3.2.3 Hareketli ortalama yöntemi	27
3.2.4 Üstel düzeltme yöntemi	27
3.2.5 Box-Jenkins yöntemi.....	28
3.2.6 Otoregresif hareketli ortalamalar (AR-MA) yöntemi	28
3.2.7 Otoregresif entegre hareketli ortalamalar (ARIMA) yöntemi	30
4. YAPAY SİNİR AĞLARI.....	31
4.1 Yapay Sinir Ağlarının Tarihçesi Ve Yapılan Önemli Çalışmalar	31
4.2 Yapay Sinir Ağlarının Genel Özellikleri.....	32
4.3 Yapay Sinir Ağlarının Dezavantajları	34
4.4 Yapay Sinir Ağlarının Kullanıldığı Alanlar	36
4.5 Yapay Sinir Ağlarının Yapısı ve Temel Elemanları	37

4.5.1 Biyolojik sinir hücresi	37
4.5.2 Yapay sinir hücresi.....	38
4.6 Biyolojik Ve Yapay Sinir Ağlarının Karşılaştırılması	43
4.7 Yapay Sinir Ağlarının Yapısı	43
4.8 Yapay Sinir Ağlarının Sınıflandırılması (YSA Mimarisi)	46
4.8.1 İleri beslemeli yapay sinir ağları	47
4.8.2 Geri beslemeli yapay sinir ağları.....	47
4.9 Yapay Sinir Ağlarında Öğrenme Stratejileri	48
4.9.1 Eğitici (supervised) öğrenme	48
4.9.2 Destekleyici (reinforcement) öğrenme.....	49
4.9.3 Eğitici (unsupervised) öğrenme	50
4.10 Yapay Sinir Ağlarında Öğrenme Kuralları.....	50
4.10.1 Hebb öğrenme kuralı.....	51
4.10.2 Hopfield öğrenme kuralı	51
4.10.3 Delta öğrenme kuralı	51
4.10.4 Kohonen öğrenme kuralı.....	52
4.11 Yapay Sinir Ağlarının Eğitilmesi Ve Test Edilmesi	52
5. YSA İLE DOĞAL GAZ TÜKETİM TAHMİNİ.....	53
5.1 Konya Bölgesi İçin Doğal Gaz Tüketim Öngörüsü	53
5.2 Doğal Gaz Tüketimine Etki Eden Parametreler	55
5.2.1 Abone sayısı (BBS).....	55
5.2.2 Meteorolojik parametreler	56
5.2.2.1 Sıcaklık.....	56
5.2.2.2 Nem	58
5.2.2.3 Yağış miktarı	59
5.2.2.4 Rüzgâr hızı	60
5.2.3 Türetilmiş parametreler	60
5.2.3.1 Derece-gün (HDD).....	61
5.2.3.2 Hissedilen sıcaklık.....	62
5.2.3.3 Rüzgâr etkisi (wind chill).....	64
5.2.4 Diğer parametreler.....	65
5.2.4.1 Doğal gaz satış fiyatı	66
5.3 Çalışmada Kullanılan YSA Yapısı Ve Mimarisi.....	66
5.4 Yapay Sinir Ağlarının Eğitilmesi ve Test Edilmesi	68
5.4.1 Levenberg-Marquardt metodu ile ileri-beslemeli YSA eğitimi	69
5.4.2 Levenberg-Marquardt algoritması.....	69
5.5 Yapay Sinir Ağlarının Test Edilmesi ve Performans Kriterleri	71
5.6 YSA Uygulaması ve MATLAB (nntool) Kullanımı	73
5.7 YSA Uygulaması.....	74
5.8 YSA Model Sonuçlarının Regresyon Model Sonuçlarıyla Karşılaştırılması ...	86
6. SONUÇ VE TARTIŞMA.....	89
KAYNAKLAR.....	97

KISALTMALAR

ADALINE	: Uyarlamalı Doğrusal Nöron (Adaptive Linear Neuron)
AIC	: Akaike Enformasyon Kriteri (Akaike Information Criteria)
AR	: Otoregresif (Autoregressive)
ARIMA	: Otoregresif Entegre Hareketli Ortalama (Autoregressive-Integrated Moving Average)
ARMA	: Otoregresif Hareketli Ortalama (Autoregressive-Moving Average)
ART	: Uyarlamalı Rezonans Teorisi (Adaptive Resonance Theory)
BBS	: Birim Bölme Sayısı
BOTAŞ	: Boru Hatları ile Petrol Taşıma Anonim Şirketi
CNG	: Sıkıştırılmış Doğal Gaz (Compressed Natural Gas)
ÇA	: Çok Katmanlı Algılayıcılar
DPK	: Doğal Gaz Piyasası Kanunu
EİE	: Elektrik İşleri Etüt İdaresi
EKK	: En Küçük Kareler
EPDK	: Enerji Piyasası Düzenleme Kurumu
EİAŞ	: Enerji Piyasası İşletme A.Ş.
ETKB	: Enerji ve Tabii Kaynaklar Bakanlığı
GKT	: Genel Kareler Toplamı
HKT	: Hata Kareler Toplamı
LM	: Levenberg-Marquardt
LNG	: Sıvılaştırılmış Doğal Gaz (Liquefied Natural Gas)
LPG	: Sıvılaştırılmış Petrol Gazı (Liquefied Petroleum Gas)
LVQ	: Öğrenme Vektör Nicemlemesi (Learning Vector Quantization)
MA	: Hareketli Ortalama (Moving Average)
MADALINE	: Çok Tabakalı Uyarlamalı Doğrusal Nöron (Multilayer Adaptive Linear Neuron)
MATLAB	: Matris Laboratuvarı (Matrix Laboratory)
MGM	: Meteoroloji Genel Müdürlüğü
NS	: Nöron Sayısı
NWC	: Ulusal Hava Servisi (National Weather Service)
OECD	: Avrupa Ekonomik İşbirliği Örgütü (Organisation for Economic Co-operation and Development)
PİGM	: Petrol İşleri Genel Müdürlüğü
rMB	: Bağlı Ortalama Sapma (Relative Mean Bias)
rRMS	: Bağlı Ortalama Karekök (Relative Root Mean Square)
RBN	: Radyal Tabanlı Yapay Sinir Ağları (Radial Basis Neural Networks)
RKT	: Regresyon Kareler Toplamı
S.S.C.B.	: Sovyet Sosyalist Cumhuriyetler Birliği
ŞİD	: İletim Şebekesi İşleyiş Düzenlemelerine İlişkin Esaslar
TEMI	: Türkiye Enerji Piyasası İstihbaratı (Turkish Energy Market Intelligence)
TKA	: Tek Katmanlı Algılayıcılar
TP	: Türkiye Petrolleri

TÜMAS : Türkiye Meteorolojik Veri Arşiv Sistemi
UTC : Eşgüdümlü Evrensel Zaman (Coordinated Universal Time)
YSA : Yapay Sinir Ağı

SEMBOLLER

G	: Jakobiye Matrisi
$J(w)$	: Öngörü hatalarının toplamı
N	: Örnek sayısı
Net_j	: j . Nöronun net değeri
R	: Rezidüel vektör
l	: İterasyon adımı
n	: Model mertebesi
q	: Model derecesi
r	: Çoklu regresyon katsayısı
$\hat{w}(l)$	: Düzenlenmiş ağırlık
α	: Üstel düzeltme katsayısı
σ_x^2	: Öngörü hatasının varyansını
η	: Öğrenme oranı
θ_j	: j . nöron için eşik değeri

ÇİZELGE LİSTESİ

Sayfa

Çizelge 2.1 : Türkiye Doğal Gaz Üretim Miktarları (Milyon Sm ³) (EPDK, 2015). .	11
Çizelge 2.2 : Türkiye doğal gaz alım anlaşmaları (Url-2).	13
Çizelge 2.3 : Spot LNG ithalatı yapan şirketlerin payları (%) (EPDK, 2015).	14
Çizelge 2.4 : Türkiye doğal gaz ithalat miktarları (milyon Sm ³) (EPDK, 2015).	15
Çizelge 2.5 : Türkiye doğal gaz ihracat miktarları (milyon Sm ³) (EPDK, 2015).	16
Çizelge 4.1 : Biyolojik ve yapay sinir ağlarının karşılaştırılması (Karahan, 2011). .	43
Çizelge 5.1: YSA’larda kullanılan giriş parametreleri.	74
Çizelge 5.2: 17 girişli ağlarda farklı gizli tabaka NS göre başarımlar değerleri.....	75
Çizelge 5.3: Giriş parametrelerinin sonuçlara etkisi.....	78
Çizelge 5.4: Değiştirilen gizli tabaka nöron sayılarına göre YSA başarımları.....	80
Çizelge 5.5: Değiştirilen gizli tabaka nöron sayılarına göre YSA başarımları.....	83
Çizelge 5.6: Basit doğrusal regresyon katsayıları.....	86
Çizelge 5.7: Çoklu doğrusal regresyon katsayıları.	87

ŞEKİL LİSTESİ

Sayfa

Şekil 2.1 : 2015 yılı küresel birincil enerji tüketim oranları (TP, 2015).....	6
Şekil 2.2 : Dünya enerji talebinin kaynak bazında tahmini gösterimi (TP, 2015).....	7
Şekil 2.3 : Dünya ispatlanmış doğal gaz rezervlerinin 2014 yılı dağılımı (TP, 2015).....	7
Şekil 2.4 : 2014 yılı en fazla doğal gaz rezervine sahip ilk 10 ülke (TP, 2015).....	8
Şekil 2.5 : Türkiye birincil enerji talebi ve tüketimin sektörel dağılımı (TP, 2015). ..	9
Şekil 2.6 : 2015 yılı illere göre doğal gaz üretim oranları (%) (EPDK, 2015).....	12
Şekil 2.7 : 2015 yılı doğal gaz üretimi yapan şirketlerin payları (EPDK, 2015).....	12
Şekil 2.8 : 2015 yılı tedarikçi bazında doğal gaz ithalat miktarları (EPDK, 2015). ..	15
Şekil 2.9 : Botaş ve diğer şirketlerin doğal gaz arzındaki payları (EPDK, 2015).	16
Şekil 2.10 : Türkiye doğal gaz arzı sağlanan iller (EPDK, 2015).	19
Şekil 2.11 : Türkiye doğal gaz depolama tesisleri ve projeleri (Url-3).	20
Şekil 3.1: Regresyon doğrusu (Şehirlioglu, 2008).....	24
Şekil 3.2: Zamana göre çeşitli talep düzenleri (Üreten, 2005).	26
Şekil 4.1: Biyolojik sinir hücresinin (nöron) yapısı (Fausett, 1994).	38
Şekil 4.2: McCulloch-Pitts nöron modeli (Barutçu, 2013).....	39
Şekil 4.3: Modern nöron modeli (Barutçu, 2013).....	40
Şekil 4.4: Aktivasyon fonksiyonu örnekleri (Barutçu, 2013).....	42
Şekil 4.5: Yapay sinir ağlarının kara kutu benzetmesi (Öztemel, 2012).	44
Şekil 4.6: YSA'yı oluşturan tabakalar (Barutçu, 2013).....	44
Şekil 4.7: Bir yapay sinir ağı örneği (Öztemel, 2012).	45
Şekil 4.8: Çeşitli YSA mimarileri (Kartalopoulos, 1996).	46
Şekil 4.9: Çeşitli ileri beslemeli yapay sinir ağı mimarileri (Barutçu, 2013).	47
Şekil 4.10: Eğitici öğrenme (Masters, 1993).....	49
Şekil 4.11: Destekleyici öğrenme (Masters, 1993).....	49
Şekil 4.12: Eğitici öğrenme (Masters, 1993).....	50
Şekil 5.1: Konya ili 2005-2015 yılları arası doğal gaz tüketimi.	54
Şekil 5.2: Abone sayısı ile tüketimin değişimi.	55
Şekil 5.3: Günlük sıcaklık değerlerinin zamanla değişimi.	57
Şekil 5.4: Günlük doğal gaz tüketiminin sıcaklık ile değişimi.	58
Şekil 5.5: Günlük doğal gaz tüketiminin nem ile değişimi.....	59
Şekil 5.6: Günlük doğal gaz tüketiminin yağış miktarı ile değişimi.	59
Şekil 5.7: Günlük doğal gaz tüketiminin rüzgar hızı ile değişimi.	60
Şekil 5.8: Doğal gaz tüketiminin sabit kaldığı baz sıcaklığın bulunması.	61
Şekil 5.9: Doğal gaz tüketimi ile derece gün arasındaki ilişki.....	62
Şekil 5.10: Sıcaklık, nem ve hissedilen sıcaklık arasındaki ilişki.	63
Şekil 5.11: Doğal gaz tüketimi ile hissedilen sıcaklık arasındaki ilişki.....	64
Şekil 5.12: Sıcaklık, rüzgar hızı ve wind-chill arasındaki ilişki.	65
Şekil 5.13: Doğal gaz satış fiyatının kullanıcı tüketimlerine etkisi.	66
Şekil 5.14: Tez çalışmasında kullanılan genel YSA yapısı.	67
Şekil 5.15: Örnek bir YSA [17,11,1] yapısının MATLAB gösterimi.	73
Şekil 5.16: Gizli tabakadaki NS değiştirilerek farklı ağ yapılarının denenmesi.	76

Şekil 5.17: Model [17,14,1] sonuçları ile fiili sonuçların karşılaştırılması.	77
Şekil 5.18: Çıkarılan giriş parametrelerinin sonuçlara etkileri.	79
Şekil 5.19: Çıkarılan giriş parametrelerinin sonuçlara etkileri (bbs dışında).	79
Şekil 5.20: Değiştirilen gizli tabaka nöron sayılarına göre YSA başarımları.....	81
Şekil 5.21: Model [12,15,1] sonuçları ile fiili sonuçların karşılaştırılması.	82
Şekil 5.22: Değiştirilen gizli tabaka nöron sayılarına göre YSA başarımları.....	84
Şekil 5.23: Model [12,15,1] sonuçları ile fiili sonuçların karşılaştırılması	85
Şekil 5.24: Basit doğrusal regresyon modeli ile fiili sonuçların karşılaştırılması.	87
Şekil 5.25: Çoklu doğrusal regresyon modeli ile fiili sonuçların karşılaştırılması....	88

YAPAY SİNİR AĞLARIYLA KONYA BÖLGESİNDE KULLANICI DOĞAL GAZ TÜKETİM ÖNGÖRÜSÜ

ÖZET

Ülkelerin ekonomik ve sosyal gelişiminin en temel gereksinimlerinden biri olan enerji, toplumsal yaşamın sürdürülebilmesi için gerekli olan hemen hemen tüm süreçler için vazgeçilmez bir girdidir. Günümüzde dünyada tüketilen enerji, birçok farklı enerji kaynağından temin edilirken; petrol, doğal gaz ve kömür gibi fosil kaynaklar, bu kaynakların %87'sini oluşturmaktadır. Petrol, dünya birincil enerji tüketiminde en büyük paya sahip olurken, petrolden sonra kömür ve doğal gaz gelmektedir. Türkiye'de ise, birincil enerji tüketiminde doğal gaz birinci sırada yer alırken, doğal gazdan sonra kömür ve petrol gelmektedir.

Tüketimini karşılayacak yerel doğal gaz rezervi ve üretimi bulunmayan Türkiye, gelişen ekonomisi ve sanayisi ile dünyanın önemli enerji tüketicileri arasında yer almaktadır. Doğal gazın Türkiye'de kullanımının yaygınlaşması ve ülke enerji talebinin giderek artış göstermesine paralel olarak, doğal gazın kullanım oranı ve kullanım alanları giderek artmış ancak yurt içi rezervler bu talebi karşılamada kısıtlı kalmıştır. Bu durum, Türkiye için doğal gaz ithalatını zorunlu hale getirmiştir. Doğal gaz temini noktasında tamamen dışa bağımlı olduğumuz ve depolama kapasitemizin çok düşük olduğu hususları göz önünde bulundurulduğunda doğal gaz sektörünün daha sağlıklı işleyebilmesi için tüketilen doğal gaz miktarının tahmini son derece önemli bir rol oynamaktadır. Talebin doğru bir şekilde tahmini, sektöre yapılacak yatırımları ve gaz alımı ile ilgili anlaşmaları, dolayısıyla sektörün gelişimini etkileyecek unsurlardan birini oluşturmaktadır.

Bu çalışmada, yapay sinir ağları (YSA) kullanılarak Konya bölgesine ait günlük doğal gaz tüketim tahmini yapılmıştır. Yapay sinir ağları, örnekleri kullanarak olayları öğrenebilen ve çevreden gelen olaylara karşı nasıl tepkiler üretebileceğini belirleyebilen bilgisayar programlarıdır. Doğrusal olmayan karmaşık problemleri çözümleyebilme, kendi kendine öğrenebilme, genelleme yapabilme, eğitildikten sonra eksik veriler ile çalışabilme ve yüksek gürültü toleransına sahip olma gibi üstün özellikler, yapay sinir ağlarının geleneksel tahmin yöntemlerine göre tercih edilmesinin nedenlerinden bazılarıdır. YSA'nın öğrenebilmesi için örneklerin belirlenmesi ve bu örneklerin ağa gösterilerek istenen çıktılara göre ağı eğitilmesi gerekmektedir. Örneklerden öğrenmenin temelinde, herhangi bir olay hakkında verilen gerçekleşmiş örneklere bakılarak ilgili olayın girdi ve çıktıları arasındaki ilişkileri öğrenmek ve daha sonra oluşacak yeni örneklerin çıktılarını belirlerken bu ilişkileri kullanmak yatmaktadır.

Çalışmada, Konya iline ait doğal gaz tüketimini etkilediği düşünülen 17 ayrı girdi değeri belirlenmiş ve kullanılmıştır. Doğal gaz tüketimine etki eden girdi parametreleri; doğal gaz kullanan abone sayısını temsilen bbs (birim bölme sayısı),

meteorolojik parametreler (sıcaklık, nem, rüzgar hızı, yağış miktarı, gün öncesi sıcaklıkları ve gün öncesi sıcaklık farkları), bu parametrelerden türetilmiş diğer önemli parametreler (derece gün, hissedilen sıcaklık, rüzgar etkisi-windchill) ve doğal gaz satış fiyatı olarak ele alınmıştır. Çalışmada kullanılan çıkış veri seti ise Enerya Konya Gaz Dağıtım A.Ş.'den temin edilmiş olup, 2005-2015 yılları arasındaki Sm^3 cinsinden günlük doğal gaz tüketim miktarlarından oluşmaktadır.

Konya iline ait olan 2005-2015 yılları arasındaki 11 senelik giriş-çıkış verisinin 10 senelik kısmı (2005-2014 yılları) ağların eğitilmesi için kullanılırken, 1 senelik veri seti (2015 yılı) test için kullanılmıştır. Test sonuçları R^2 , r_{RMS} ve r_{MB} olmak üzere üç ayrı performans kriteri ile ölçülerek Konya için en uygun yapay sinir ağ modeli bulunmaya çalışılmıştır. Bu kapsamda, öncelikle doğal gaz tüketimi üzerinde etkisi olan parametreler belirlenmiş ve bu parametreler ile doğal gaz tüketim miktarı arasındaki ilişki açıklanmıştır. Daha sonra, kullanılacak olan yapay sinir ağı mimarisi ve öğrenme algoritması belirlenerek birçok farklı deneme yapılmış ve en doğru sonuçları veren ağın bulunması için çalışılmıştır. Son olarak, yapay sinir ağlarıyla elde edilen ve yüksek başarımlı veren ağ sonuçları basit ve çoklu doğrusal regresyon model sonuçlarıyla karşılaştırılmıştır.

FORECASTING OF NATURAL GAS CONSUMPTION BY ARTIFICIAL NEURAL NETWORKS IN KONYA REGION

SUMMARY

Economic growth, along with accompanying structural changes, strongly influences world energy consumption. As countries develop and living standards improve, energy demand grows rapidly. The consumption of energy from all sources increases and fossil fuels continue to provide most of the world's energy. While oil remains the world's dominant fuel with the largest share in the global primary energy consumption, it is followed by coal and natural gas. But in Turkey, natural gas comes first in primary energy consumption, followed by coal and oil.

With a rapidly growing economy, Turkey has become one of the fastest growing energy markets in the world. In parallel with the widespread use of natural gas in Turkey and the increasing demand for energy, the utilization rate and consumption areas of natural gas have increased steadily, but the domestic reserves have been limited in meeting this demand. This situation has made natural gas imports compulsory for Turkey who has limited natural gas reserves and storage capacity. Turkey imports nearly 99% of the natural gas it consumes. So it is crucial to predict the natural gas consumption for our country who follows a foreign dependent policy to yield natural gas and whose storage capacity is very limited. True prediction of the natural gas demand becomes one of the most important elements which affects the investments to be made in the sector and agreements on gas purchasing. In this manner, there are many demand forecasting methods which are used for the natural gas consumption.

In this study, the daily natural gas consumption of Konya region has been predicted by artificial neural networks (ANN). Artificial neural network is a useful tool which is used to solve complex, especially nonlinear decision problems, optimization, process control, forecast and many others. ANNs are computer programs that can learn how to use events and how they can generate responses to events that surround them. The ability to solve non-linear complex problems, self-learning, generalization, working with missing data after training, and having high noise tolerance are some of the reasons for choosing ANNs compared to traditional estimation methods.

An artificial neuron consists of five main components which are the inputs, weights, summation function, activation function and the outputs: The inputs are the information coming from the outside world to the cell, and they do not perform any mathematical operation but transfers the data to a forward step. In this study, 17 inputs which are thought to affect the natural gas consumption of Konya region have been determined and used. Input parameters affecting natural gas consumption; bbs representing the number of natural gas clients, meteorological parameters (temperature, humidity, wind speed, precipitation amount, day ahead temperature and day before temperature difference), other important parameters derived from

meteorological parameters (heating degree-day (hdd), heat-index, wind-chill) and natural gas sales price.

The weights represent the importance of the information its effect on the cell coming from input. The learning process on the networks is achieved by changing the weights. In this study, Levenberg - Marquardt (LM) learning algorithm was chosen for the training of artificial neural networks. The summation function multiplies the input values by their weights and provides the net entry to the network.

The net entry coming from the summation function is processed to determine the output to be produced as response for this net input by the activation function. In this study, Logarithmic Sigmoid activation function was used in the hidden layer while Pure-linear activation function was used in the exit layer. Finally, the output value is given as the output of the model which is determine by the activation functions after the learning process ended. The output data set used in the study was obtained from Enerya Konya Gas Distribution Inc. and consists of daily natural gas consumption amounts (mainly used for space heating, water heating and cooking) in Sm^3 between 2005 and 2015.

In this study, the ANN architecture was determined as feed-forward network and several trials were conducted to develop the best network model suitable for this architecture. To train the neural networks, 10-year part of the 11-year input-output data between 2005 and 2015 belonging to Konya province was used while the one-year data set (2015) was used for testing. Test results were measured with three different performance criteria which are R^2 , $rRMS$, rMB and the most suitable ANN model for Konya was investigated. After the parameters affecting natural gas consumption were determined, the relationship between these parameters and the daily gas consumption values was explained.

In the modelling part, firstly, the best ANN model was tried to be obtained by using all the 17 input parameters and changing the number of neurons in the hidden layer. When all input parameters are used, the network structure with 14 neurons in the hidden layer gave the highest R^2 value and the lowest $rRMS$ value. Then the effect of each parameter on the estimation results on the best network structure was investigated. In this framework, the parameters that have the highest effect on consumption were determined as well as the parameters neither change the results nor achieve better results if they are not used. With this feedback, 5 parameters (day before maximum temperature, day ahead average temperature difference, day before minimum temperature, degree day, windchill) were excluded, and the results from new network trials were recorded.

At the end of the modeling studies, it has been tested whether the previously obtained results can be achieved by testing new network structures in which all temperature parameters and input parameters with easier accessibility are included. 5 parameters (heat index, windchill, daily average wind speed, daily total precipitation and natural gas sales price) which have no significant effect on natural gas consumption were excluded and the new results were recorded. With this ANN structure almost the same performance results were obtained.

Finally, ANN results were compared with the simple linear regression and multi linear regression model results. The results showed that the ANN models are more feasible than the regression models.

Compared with the actual daily natural gas consumption values, the ANN outputs (prediction) in modeling studies show that the network can produce near-realistic output values even for one year. This is a big advantage for the distribution companies in order to plan the gas trade volumes even one year ago which means signing on true volumes of natural gas supply agreements.

When the prediction results were investigated, it was seen that the accuracy of the selected network structure and the model performance are higher especially in the winter months. The importance of the true prediction and the planning is more pronounced in the winter. However, during the months of May, October, and November in which the seasonal shifts observed, the deviation from the actual values were higher than the other months. Eventhough the gas consumption volumes are lower in these months, new predition models would be developed in which the seosanal changes are specifically adressed. Beside this, it can be contributed by invastigating the working days and holidays separately to achieve better results and to develop new models.

1. GİRİŞ

Bir ülkenin ekonomik ve sosyal gelişiminin en temel gereksinimlerinden biri olan enerji, toplumsal yaşamımızı sürdürebilmesi adına gerekli olan hemen hemen tüm süreçler için vazgeçilmez bir girdi olup; sanayi, ulaştırma, konut ve ticarethane gibi ana sektörlerde kullanılmaktadır. Günümüzde dünyada tüketilen enerji, birçok farklı enerji kaynağından temin edilirken; petrol, doğal gaz ve kömür gibi fosil kaynaklar, bu kaynakların %87'sini oluşturmaktadır (TP, 2015).

Dünya birincil enerji tüketiminde en büyük paya sahip olan petrol, özellikle ulaştırma sektörünün temel enerji kaynağı konumundadır. Petrolden sonra en büyük paya sahip olan kömür ve doğal gaz ise büyük oranda elektrik üretiminde kullanılmaktadır (TP, 2015). Tüketimini karşılayacak yerel doğal gaz rezervi ve üretimi bulunmayan Türkiye ise gelişen ekonomisi ve sanayisi ile dünyanın önemli enerji tüketicileri arasında yer almaktadır. Dünya birincil enerji tüketimi incelendiğinde, petrol en büyük paya sahip olurken, Türkiye'deki birincil enerji tüketiminde ise doğal gaz birinci sırada yer almaktadır. Doğal gazdan sonra ise kömür ve petrol gelmektedir (TP, 2015).

Temiz bir yakıt olan doğal gazın emisyon miktarları diğer yakıtlara göre oldukça düşüktür. Çevreyi kirleten kükürt dioksit ve azot oksitler, kömür ve petrolle karşılaştırıldığında, doğal gazda oldukça düşük seviyede kalmaktadır. Söz konusu kaynakların yanması sonucu oluşan is ve kül parçacıkları temizlik ve insan sağlığı açısından son derece zararlıdır. Ancak, doğal gazın yanması sonucu oluşan bu partiküller kömürle karşılaştırıldığında ihmal edilebilir seviyededir.

Türkiye'nin birincil enerji ihtiyacını karşılayan doğal gazın sektörlere göre kullanım dağılımı incelendiğinde elektrik üretimi başta yer almakta olup, kalan tüketimin sırasıyla konut ve hizmet, sanayi ve ulaşım sektörlerinde kullanıldığı görülmektedir.

Türkiye'nin doğal gazla tanışması ilk kez 1970 yılında Kırklareli'nde tespit edilen doğal gaz rezervleriyle olmuştur. Bu bölgede üretilen doğal gaz sonraki yıllarda Pınarhisar Çimento Fabrikası'nda kullanılmıştır. 1985 yılında ilk kez yerli kaynaklarımızla Hamitabat Doğal Gaz Çevrim Santralinde doğal gaz kullanılarak

elektrik üretimi faaliyeti gerçekleştirilmiştir. Doğal gazın sanayide kullanılmaya başlanmasının ardından, 1988 yılında Doğal Gaz İşletmeleri Bölge Müdürlüğü faaliyete geçerek doğal gaz Ankara’da ilk kez şehir içi evsel ve ticari olarak da kullanılmaya başlanmıştır. Doğal gazın şehirlerde kullanılması Ankara’dan sonra İstanbul, Bursa, Eskişehir ve İzmit bölgelerini de içine alarak yaygınlaşmıştır.

Doğal gazın Türkiye’de kullanımının yaygınlaşması ve ülke enerji talebinin giderek artış göstermesine paralel olarak, doğal gazın kullanım oranı ve kullanım alanları giderek artmış fakat yurt içi rezervler bu talebi karşılamada kısıtlı kalmıştır. Bu durum, Türkiye için doğal gaz ithalatını zorunlu hale getirmiştir. Türkiye, doğal gazda önemli ölçüde ithalata ve ithalatta da büyük ölçüde Rusya’ya bağımlı hale gelmiştir. Günümüzde gerçekleşen boru gazı ithalatının yarısından fazlası Rusya’dan olup, Rusya’yı İran ve Azerbaycan takip etmektedir. Toplam ithalattaki payı küçük olan LNG ithalatı ise Cezayir ve Nijerya’dan yapılmaktadır (EPDK, 2015).

Türkiye Doğal Gaz Piyasasında hakim rol üstlenmeye devam eden BOTAŞ, 2015 yılında gerçekleşen 48,8 bcm (milyar Sm³) doğal gaz arzının %83 gibi büyük kısmını karşılarken; %16’lık kısmını ithalat lisansına sahip şirketler ve %1 gibi çok düşük kısmını da doğal gaz üretimi yapan toptan satış şirketleri karşılamıştır (EPDK, 2015). BOTAŞ ve diğer ithalat lisansına sahip şirketlerin, doğal gaz arzını sağlamak üzere yaptığı uluslararası doğal gaz anlaşmaları çok uzun dönemli (20-30 sene) olup, iki taraf için de bağlayıcı olan ciddi sözleşme yükümlülükleri içermektedir. Bunlardan en önemlisi, imzalanan sözleşme miktarı üzerinden yıllık ve yaz dönemi için verilen minimum alım taahhütlerinin yerine getirilmediği takdirde, cezai yaptırımların uygulanabilmesidir. BOTAŞ ve ithalat lisansına sahip diğer şirketler, bu yaptırımlardan korunmak için, üçüncü taraflarla yaptıkları satış sözleşme şartlarını da karşılıklı akreditif (back to back) yapmaktadırlar. Bu nedenle, yapılacak planlama çalışmaları içerisinde en önemli konulardan biri doğal gaz talep miktarının doğru şekilde belirlenmesidir.

Tamamen dışa bağımlı olduğumuz ve depolama kapasitemizin düşük olduğu doğal gaz sektörünün daha sağlıklı işleyebilmesi ve gelişebilmesi için talep, arz, iletim, dağıtım ve fiyatlandırma konularında gerçekçi planlar yapılması son derece önemlidir. Doğal gaz stok kapasitemizin düşük olması nedeniyle, doğal gaz talebinin doğru bir şekilde belirlenmesi doğal gaz alımı ile ilgili anlaşmaları ve yapılacak yatırımları

etkileyecektir. Talep tahmini ne kadar doğru olursa, yapılan planlama çalışmaları da o kadar sağlıklı olacaktır.

Talep tahmininin doğru yapılması, şirket yönetiminin ya da işletmelerin kısa dönemli veya uzun dönemli hedeflerine ulaşmalarında, doğru ve stratejik kararlar alabilmelerinde önemli bir etkidir. Doğru ve güvenilir tahminlerin yapılabilmesi için tahmin yönteminin iyi belirlenmesi gerekmektedir.

Bu çalışmada, yapay sinir ağları kullanılarak Konya iline ait günlük doğal gaz tüketim tahmini yapılması hedeflenmiştir. Yapısı itibarıyla yapay sinir ağları (YSA), insan beyninin öğrenme mekanizmasını basitleştirerek taklit eden matematiksel sistemlerdir. Eksik bilgiler ile çalışabilme, normal olmayan verileri işleyebilme yetenekleri ve yüksek gürültü toleransları sayesinde günümüzde pek çok alanda kullanılan yapay sinir ağları ile doğrusal olmayan (non-linear) karmaşık problemlerin de çözülmesi mümkündür.

YSA'nın öğrenilmesi için örneklerin belirlenmesi, bu örneklerin ağa gösterilerek istenen çıktılara göre ağın eğitilmesi gerekmektedir. Ağın başarısı, seçilen örneklerle sıkı bağlıdır. Örneklerden öğrenmenin temelinde, herhangi bir olay hakkında verilen gerçekleşmiş örneklerle bakarak ilgili olayın girdi ve çıktıları arasındaki ilişkileri öğrenmek ve daha sonra oluşacak yeni örneklerin çıktılarını belirlerken bu ilişkileri kullanmak yatmaktadır.

Çalışmada, ağın daha fazla örnekleme yaparak girdi ve çıktı değerleri arasında daha iyi ilişki kurulmasına olanak sağlamak üzere, Konya iline ait olan 2005-2015 yılları arasındaki 11 senelik giriş-çıkış verisinin 10 senelik kısmı (2005-2014) ağların eğitilmesi için kullanılırken, 1 senelik veri seti (2015) test için kullanılmıştır. Test sonuçları farklı performans kriterleriyle ölçülerek Konya için en uygun yapay sinir ağ modeli bulunmaya çalışılmıştır. Bu kapsamda, öncelikle doğal gaz tüketimi üzerinde etkisi olan parametreler belirlenmiş ve bu parametreler ile doğal gaz tüketim miktarı arasındaki ilişki açıklanmıştır. Daha sonra, kullanılacak olan yapay sinir ağı mimarisi ve öğrenme algoritması belirlenerek birçok farklı deneme yapılmış ve en doğru sonuçları veren ağın bulunması için çalışılmıştır. Son olarak, yapay sinir ağlarıyla elde edilen ve yüksek başarımlar veren ağ sonuçları basit ve çoklu doğrusal regresyon model sonuçlarıyla karşılaştırılmıştır.

2. DOĞAL GAZ PİYASASI

Bu bölümde, enerji kaynağı olarak doğal gazın, dünya ve Türkiye piyasalarındaki yeri, birincil enerji kaynakları içindeki payı, rezerv, üretim ve tüketim değerleri incelendikten sonra, Türkiye Doğal Gaz Piyasasında yürütülen faaliyetlere değinilecektir.

2.1 Enerji Kaynağı Olarak Doğal Gaz

Bir petrol türevi olan doğal gaz, yanıcı, havadan hafif, renksiz ve kokusuz bir gazdır. Doğalgaz; başta metan (CH_4) ve etan (C_2H_6) olmak üzere birçok hidrokarbondan ve karbondioksit (CO_2), helyum, hidrojen sülfid, azot gibi çeşitli gazlardan oluşmaktadır. Yer altında genellikle petrol ile birlikte veya gaz rezervuarlarında bulunmaktadır. Kaynağından çıkarıldığı haliyle, herhangi bir işlem görmeksizin, birincil enerji kaynağı olarak kullanılabilen doğal gaz, boru hatları veya sıvılaştırılmak suretiyle tankerler ile taşınabilmektedir (ETKB, 2016).


Doğal gaz ve diğer yakıtların yanma işlemleri sonucu açığa çıkan enerji genellikle yakıtın alt kalorifik değerini verir. Kalorifik değer, katı ve sıvı yakıtlarda kcal/kg, gaz yakıtlarda kcal/m³ olarak ifade edilir. Hafif sıvı yakıtlarda kalorifik değer genellikle kcal/litre olarak verilir. Kalorifik değer kullanımında uluslararası uygulamalar değişim göstermektedir. Avrupa’da diğer yakıtlarda alt kalorifik değer kullanımının yaygın olmasına rağmen doğal gazda üst kalorifik değer kullanılması konusunda bir anlaşmaya varılmıştır. Alt ve üst kalorifik değer arasındaki fark, yakıt içinde bulunan hidrojen miktarının bir fonksiyonudur. Örneğin, hidrojen miktarı düşük olan taş kömürünün alt ve üst kalorifik değerleri arasındaki fark çok küçük olurken, hidrojen miktarı yüksek olan doğal gazın alt ve üst kalorifik değerleri arasındaki fark çok fazladır (Url-1). Doğal gazın alt kalorifik değeri 8200 kcal/nm³ iken, üst kalorifik değeri 9155 kcal/nm³’tür. Gaz yakıtlarında kullanılan nm³ (Normal Metreküp) birimi, 0°C sıcaklık ve 1,01325 bar mutlak basınçtaki gazın hacmini ifade eder. Doğal gaz piyasasında kullanılan Sm³ (Standart Metreküp) ise 15°C sıcaklıkta ve 1,01325 Bar mutlak basınçta bir metreküplük hacim dolduran, su buharı içermeyen ve Üst Kalorifik

Değeri 9155 kcal olan, doğal gaz miktarını ifade eder (ŞİD). Temiz bir yakıt olan doğal gazın emisyon miktarları diğer yakıtlara göre oldukça düşüktür. Çevreyi kirleten kükürt dioksit ve azot oksitler, kömür ve petrolle karşılaştırıldığında, doğal gazda oldukça düşük seviyededir. Yanma sonucu oluşan is ve kül parçacıkları temizlik ve insan sağlığı açısından son derece zararlıdır. Doğal gazın yanması sonucu oluşan bu partiküller kömürle karşılaştırıldığında neredeyse yok denecek kadar azdır (Url-1).

Yine aynı şekilde, çeşitli yakıt türlerinin kullanıldığı alanlara göre, yanma sonucu oluşan metan ve azot oksitlerin emisyon faktörleri karşılaştırıldığında, doğal gazın diğer yakıtlara göre emisyon miktarları daha az olmaktadır.

2.2 Küresel Doğal Gaz Sektörünün Görünümü


Bir ülkenin ekonomik ve sosyal gelişiminin en temel gereksinimlerinden biri olan enerji, toplumsal yaşamımızı sürdürebilmemiz adına gerekli olan hemen hemen tüm süreçler için vazgeçilmez bir girdi olup; sanayi, ulaştırma, konut ve ticarethane gibi ana sektörlerinde kullanılmaktadır. Günümüzde dünyada tüketilen enerji, birçok farklı enerji kaynağından temin edilirken; petrol, doğal gaz ve kömür gibi fosil kaynaklar, bu kaynakların %87'sini oluşturmaktadır (TP, 2015). 2015 yılı küresel birincil enerji tüketim oranları Şekil 2.1'de gösterilmiştir.



Şekil 2.1 : 2015 yılı küresel birincil enerji tüketim oranları (TP, 2015).

Dünya birincil enerji tüketiminde en büyük paya sahip olan petrol, özellikle ulaştırma sektörünün temel enerji kaynağı konumundadır. Petrolden sonra en büyük paya sahip olan kömür ve doğal gaz ise büyük oranda elektrik üretiminde kullanılmaktadır. 2014 yılında, birincil enerji kaynaklarının % 42'si elektrik üretimi için kullanılmış olup

2035 yılında bu rakamın % 45,5'e çıkması beklenmektedir (TP, 2015). Şekil 2.2'de de gösterildiği üzere, yapılan çeşitli projeksiyonlara göre 1990-2035 yılları arasında enerji talebinin giderek artması ve petrol ve doğal gazın birincil enerji tüketimi içerisindeki paylarının uzun dönemde de günümüzdeki seviyelerde seyretmesi beklenmektedir (TP, 2015).




Şekil 2.2 : Dünya enerji talebinin kaynak bazında tahmini gösterimi (TP, 2015).

2.2.1 Küresel doğal gaz rezervleri ve üretimi

2013 yılında 186,5 trilyon Sm^3 olarak belirlenen dünya doğal gaz rezervi, 2014 yılında bir önceki yıla göre % 0,3 artarak 187,1 trilyon Sm^3 olarak kaydedilmiştir (TP, 2015).


Şekil 2.3'te, 2014 yılı sonu itibariyle dünyada ispatlanmış olan doğal gaz rezervlerinin dağılımı gösterilmektedir (TP, 2015).



Şekil 2.3 : Dünya ispatlanmış doğal gaz rezervlerinin 2014 yılı dağılımı (TP, 2015).

Dünya doğal gaz rezervinin % 42,7'si Orta Doğu'da, % 29,3'ü Avrasya'da, % 8,2'si Asya Pasifik'te, % 7,6'sı Afrika'da, % 6,5'i Kuzey Amerika'da ve % 1,7'si ise Avrupa'da bulunmaktadır. OECD ülkelerinin doğal gaz rezervi ise 18,6 trilyon Sm³ olup, toplam rezervin % 10,4'ünü oluşturmaktadır.

2014 yılı itibariyle en fazla doğal gaz rezervine sahip ilk on ülke ve rezerv miktarları Şekil 2.4.'te gösterilmektedir (TP, 2015).



Şekil 2.4 : 2014 yılı en fazla doğal gaz rezervine sahip ilk 10 ülke (TP, 2015).


2013 yılında 3,30 trilyon Sm³ olarak gerçekleşen küresel doğal gaz üretimi, 2014 yılında bir önceki yıla göre % 1,6 artışla 3,46 trilyon Sm³ olarak kaydedilmiştir. 2015 yılına ilişkin ilk veriler itibariyle ise, doğal gaz üretimi % 2,4 artarak 3,54 milyar Sm³ olarak gerçekleşmiştir (TP, 2015).

2.2.2 Küresel doğal gaz tüketimi

2014 yılında küresel doğal gaz talebi, bir önceki yıla göre % 0,4 artarak, 3,4 trilyon Sm³ olarak gerçekleşmiştir. 2015 yılına ilişkin ilk verilere göre, doğal gaz tüketimi 2014 yılına göre % 3,1 artarak 3,5 trilyon Sm³ olarak gerçekleşmiştir.

2.3 Türkiye Doğal Gaz Sektörünün Görünümü

Tüketimi karşılayacak doğal gaz rezervleri ve doğal gaz üretimi bulunmayan Türkiye, gelişen ekonomisi ve sanayisi ile dünyanın önemli enerji tüketicileri arasında yer almaktadır. Dünya birincil enerji tüketiminde petrol en büyük paya sahip olurken, Şekil 2.5'te gösterildiği gibi 2014 yılı verilerine göre Türkiye'deki birincil enerji tüketiminde doğal gaz % 32,5 pay ile birinci sırada yer almaktadır (TP, 2015). Doğal gazdan sonra ise % 29,2 ile kömür ve % 28,5 ile petrol gelmektedir.



Şekil 2.5 : Türkiye birincil enerji talebi ve tüketimin sektörel dağılımı (TP, 2015).

2014 yılı verilerine göre Türkiye birincil enerji talebinin sektörlere göre dağılımı incelendiğinde; toplam tüketimin % 30'u çevrim sektöründe elektrik üretimi amacıyla kullanılmaktadır. Doğal gazın sektörlere göre kullanım dağılımı incelendiğinde ise, elektrik üretimi haricinde kalan tüketimin % 24'ünün konut ve hizmet sektöründe, % 23'ünün sanayide ve % 19'unun ise ulaştırma sektöründe kullanıldığı görülmektedir.

2.3.1 Türkiye doğal gaz rezervleri ve üretimi

Doğal gaz talebinin %99,2'si ithalatla karşılanan ülkemizde, 2015 yılında 48,8 milyar Sm^3 doğal gaz tüketilmiş ve bu rakamın sadece %0,8'i (399 milyon Sm^3) yerel kaynaklar ile karşılanmıştır. Türkiye'nin 2015 yılında yerli doğal gaz üretiminin tüketime oranı ise son on yılın en düşüğü olup, % 0,8 olarak gerçekleşmiştir. 2008 yılında 1 milyar Sm^3 'e kadar çıkan doğal gaz üretimi, 2015 yılında 399 milyon Sm^3 'e düşmüştür (TP, 2015). 2016 yılı Haziran ayı sonu itibarı ile yerel üretilebilir doğal gaz rezervimiz ise 18,7 milyar Sm^3 olarak tespit edilmiştir (ETKB, 2016).

2.3.2 Türkiye doğal gaz tüketimi

Türkiye'nin enerji kaynakları bakımından dışa bağımlılığı oldukça yüksek seviyededir. 1990'ların başından itibaren doğal gaz tüketimindeki büyük yükselişe bağlı olarak dışa bağımlılık oranı da artış göstermiş ve 2000'li yılların başından itibaren %70'ler civarında seyretmeye başlamıştır. 2015 yılı doğal gaz tüketimi 48,8 milyar Sm^3 olup bu miktarın sadece % 0,8'i (399 milyon Sm^3) ülke içi üretim ile karşılanmıştır (TP, 2015).

2.4 Türkiye Doğal Gaz Piyasasının Yapısı

Türkiye'nin doğal gazla tanışması ilk kez 1970 yılında Kırklareli'nde tespit edilen doğal gaz rezervleriyle olmuştur. Bu bölgede üretilen doğal gaz sonraki yıllarda Pınarhisar Çimento Fabrikası'nda kullanılmıştır. 1974 yılında, Türkiye Petrolleri Anonim Ortaklığı (TPAO) tarafından Boru Hatları ile Petrol Taşıma Anonim Şirketi (BOTAŞ) kurulmuştur. 1975 yılında Mardin Çamurlu sahasında bulunan doğal gaz, 1982 yılında Mardin Çimento Fabrikası'na verilmiştir. Doğal gazın sanayi ve şehir şebekelerinde kullanımının yaygınlaşması için 1984 yılında Türkiye ve S.S.C.B. arasında doğal gaz sevkiyatı anlaşması imzalanmıştır. 1985 yılında ilk kez yerli kaynaklarımızla Hamitabat Doğal Gaz Çevrim Santralinde doğal gaz kullanılarak elektrik üretimi faaliyeti gerçekleştirilmiştir. Doğal gazın sanayide kullanılmaya başlanmasının ardından, 1988 yılında Doğal Gaz İşletmeleri Bölge Müdürlüğü faaliyete geçerek doğal gaz Ankara'da ilk kez şehir içi evsel ve ticari olarak da kullanılmaya başlanmıştır. 1989 yılında ise Ambarlı Doğal Gaz Çevrim Santralinde doğal gaz kullanılarak elektrik üretimi başlamıştır. Doğal gazın şehirlerde kullanılması Ankara'dan sonra İstanbul, Bursa, Eskişehir ve İzmit bölgelerini de içine alarak yaygınlaşmıştır.

İthal edilen doğal gaz ile BOTAŞ tarafından satın alınan yerli doğal gazın; satışı, satış fiyatının belirlenmesi, ticareti, iletimi ve depolaması uzun zaman boyunca kamu tüzel kişiliği olan BOTAŞ'ın tekelinde olmuştur. Bunların yanı sıra BOTAŞ, hem doğal gaz faaliyetleri amacıyla kurulan şirketlere ortak olabilmiş hem de yılda 1.000.000 Sm³'ten fazla doğal gaz kullanan sanayi kuruluşlarına ve Organize Sanayi Bölgelerine doğal gaz satış yetkisini kendisinde bulundurmıştır.

1980'li yıllardan itibaren dünyada başlayan enerji piyasalarının liberalleştirilmesi ve serbestleştirilmesi eğilimi neticesinde, tekelleri piyasaların rekabete açılması hız kazanmış ve Türkiye'de de buna yönelik ilk adım 2001 yılında Doğal Gaz Piyasası Kanunu'nun (DPK) yasalaşmasıyla atılmıştır.

4646 sayılı bu kanunun amacı kanunda yazan haliyle; doğal gazın kaliteli, sürekli, ucuz, rekabete dayalı esaslar çerçevesinde çevreye zarar vermeyecek şekilde tüketicilerin kullanımına sunulması için, doğal gaz piyasasının serbestleştirilerek mali açıdan güçlü, istikrarlı ve şeffaf bir doğal gaz piyasasının oluşturulması ve bu piyasada

bağımsız bir düzenleme ve denetimin sağlanmasıdır (DPK). Bu kanun, düzenleme ve denetlemenin mali ve idari yönden bağımsız bir otorite olan Enerji Piyasası Düzenleme Kurumu (EPDK) tarafından gerçekleştirilmesini öngörmüştür.

Kanun “ulusal iletim hatları” dışında, BOTAS’ın doğal gaz sektöründeki tekel haklarına son vermiş ve ithalat, iletim, toptan satış, dağıtım, ihracat, depolama faaliyetlerinin her birini ayrı bir lisansa tabi kılmıştır. EPDK tarafından verilen lisanslar çerçevesinde; doğal gazın üretiminden veya tedarikinden, son tüketici için kullanıma sunulmasına dek söz konusu olan faaliyetlere aşağıdaki alt başlıklarda yer verilmiştir.

2.4.1 Üretim

Türkiye’deki doğal gaz arama ve üretim faaliyetleri, 6491 sayılı Türk Petrol Kanunu’na göre Petrol İşleri Genel Müdürlüğü (PIGM) tarafından verilen arama ve işletme ruhsatları kapsamında gerçekleştirilmektedir (EPDK, 2015).


Doğal gaz üretim faaliyeti, ülkemizde 4646 sayılı Kanuna göre piyasa faaliyeti olarak sayılmamakla birlikte; üretim yapan şirketler ürettikleri gazı, EPDK tarafından toptan satış lisansı almak koşuluyla yurt içinde piyasadaki toptan satış, ithalat, ihracat, dağıtım, CNG satış, CNG iletim ve dağıtım faaliyeti yürüten şirketlere veya serbest tüketicilere; ihracat lisansı almak şartıyla da yurt dışına pazarlayabilirler.

Bu kapsamda EPDK’dan toptan satış lisansı almış şirketler tarafından üretilen doğal gaz, üretim bölgelerinde bulunan sınai ve ticari kuruluşlara, dağıtım şirketlerine ve toptan satış şirketlerine sunulmaktadır. Yıllar bazında, ülkede üretilen toplam doğal gaz miktarı Çizelge 2.1’de gösterilmekte olup, miktarlar toplam talebe göre oldukça düşük seviyededir (EPDK, 2015).

Çizelge 2.1 : Türkiye Doğal Gaz Üretim Miktarları (Milyon Sm³) (EPDK, 2015).


Yıllar	2007	2008	2009	2010	2011	2012	2013	2014	2015
Miktar	874	969	684	682	759	632	537	479	381

Şekil 2.6’da gösterildiği gibi, Türkiye’de doğal gaz üretiminin gerçekleştirildiği sahalarda en yüksek paya sahip şehir % 66,17 ile Tekirdağ olurken, ardından Kırklareli ve Düzce gelmektedir.



Şekil 2.6 : 2015 yılı illere göre doğal gaz üretim oranları (%) (EPDK, 2015).

2015 yılında 381,37 milyon Sm³ olarak gerçekleşen doğal gaz üretiminin büyük bir kısmı TPAO ve Thrace Basın Natural Gas Corporation şirketleri tarafından gerçekleştirilmiş olup, diğer lisans sahibi üretim şirketlerinin piyasadaki payları Şekil 2.7’de gösterilmiştir (EPDK, 2015).



Şekil 2.7 : 2015 yılı doğal gaz üretimi yapan şirketlerin payları (EPDK, 2015).

Söz konusu şirketlerin satışını yaptıkları gazın %65’lik kısmını nihai tüketicilere yapılan satışlar oluştururken bunu ithalat, toptan satış, dağıtım ve sıkıştırılmış doğal gaz lisansına sahip şirketler takip etmektedir.

2.4.2 İthalat

Doğal gazın Türkiye’de kullanımının yaygınlaşması ve ülke enerji talebinin giderek artış göstermesine paralel olarak, doğal gazın kullanım oranı ve kullanım alanları giderek artarken yurt içi rezervler bu talebi karşılamada kısıtlı kalmıştır. Bu durum da Türkiye için doğal gaz ithalatını zorunlu hale getirmiştir.

Türkiye’de doğal gaz ithalatı boru hatlarıyla ya da boru hatları ile iletimin teknik veya ekonomik açıdan mümkün olmadığı durumlarda ise Sıvılaştırılmış Doğal Gaz (LNG) şeklinde tankerler vasıtasıyla deniz taşımacılığı ile yapılmaktadır. Doğal gaza ilişkin ilk satın alım anlaşması Rusya ile 1986 yılında 6 milyar Sm³ için imzalanmıştır. İlerleyen yıllarda bu miktarın yeterli olmaması sebebiyle sırasıyla Rusya (İlave Batı Hattı), İran ve Rusya ile (Mavi Akım Hattı) ek anlaşmalar yapılmıştır. Rusya ve İran’dan sonra, Azerbaycan ile de 2001 yılında imzalanan uzun dönemli doğal gaz alım anlaşması kapsamında 2007 yılından itibaren kontrat kapsamında gaz alınmaya başlanmıştır (EPDK, 2015). Çizelge 2.2’de Türkiye’nin doğal gaz alım anlaşmaları ve kontrat süreleri detaylı olarak gösterilmiştir. BOTAŞ ile Gazprom Export Limited Liability Company ile 14.02.1986 tarihinde imzalanmış olan doğal gaz alım satım anlaşması 31.12.2011 tarihi itibarıyla sona ermiş ancak, aynı kapasitede doğal gaz, özel sektör tarafından ithal edilmeye başlanmıştır. 1999 yılında imzalanan sözleşmeye rağmen henüz devreye girmediği için toplama dâhil edilmeyen Türkmenistan anlaşması hariç olmak üzere, 3 farklı ülkeden uzun dönemli doğal gaz alım anlaşmaları kapsamında boru hatlarıyla doğal gaz ithalatı gerçekleştirilmektedir (Url-2).

Çizelge 2.2 : Türkiye doğal gaz alım anlaşmaları (Url-2).

Mevcut Anlaşmalar	Miktar (Milyar Sm ³ /yıl)	İmzalanma Tarihi	Durumu	Bitiş Tarihi
Rus. Fed. (Batı)	6	1986	Uzatıldı	Aralık 2011
Cezayir (LNG)	4,4	1988	Devrede	Ekim 2024
Nijerya (LNG)	1,3	1995	Devrede	Ekim 2021
İran	9,6	1996	Devrede	Temmuz 2026
Rus. Fed. (Karadeniz)	16	1997	Devrede	2025 Sonu
Rus. Fed. (Batı)	4	1998	Devrede	2021 Sonu
Türkmenistan	15,6	1999	-	-
Azerbaycan (Faz-I)	6,6	2001	Devrede	Nisan 2021
Azerbaycan (Faz-II)	6	2011	2018	2033
Azerbaycan (BIL)	0,2	2011	Devrede	2046

Boru hatları ile taşınan doğal gazın yanı sıra, arz kaynaklarının çeşitlendirilerek arz güvenliğinin sağlanması ve tedarikte esnekliğin artırılması amacıyla Sıvılaştırılmış Doğal Gaz (LNG) ithalatı da yapılabilmektedir. Boru hatları ile iletiminin teknik veya ekonomik açıdan mümkün olmadığı durumlarda doğal gaz, -162°C'a kadar soğutulmuş hacmi 600'de bir küçültülmesi suretiyle sıvılaştırılmış formda özel olarak imal edilmiş tankerler vasıtasıyla taşınmaktadır.

BOTAŞ tarafından 1988 yılında imzalanan alım anlaşması kapsamında 1994 yılından itibaren Cezayir'den, 1995 yılında imzalanan alım anlaşması kapsamında ise 1999 yılından itibaren Nijerya'dan LNG ticaretine başlanmıştır. Sadece BOTAŞ tarafından yürütülen LNG ithalatı, 2008 tarihinde yayınlanan Kanun ile BOTAŞ ve diğer piyasa katılımcıları için serbest hale gelmiş olup, tek bir ithalat (spot LNG) lisansı kapsamında birden fazla ülkeden ithalat yapılabilmesinin önü açılmıştır.

Türkiye'de LNG faaliyetlerinin yürütüldüğü iki LNG terminali bulunmaktadır. Bunlardan biri, BOTAŞ mülkiyet ve işletmesindeki Marmara Ereğlisi LNG Terminali ve diğeri de Ege Gaz A.Ş. tarafından Aliğa'da kurulan ve 2006 yılında kullanılmaya başlanan Ege Gaz A.Ş. LNG Terminalidir. Bu terminallerde, uzun dönemli sözleşmelerle alınan LNG ile spot piyasadan alınan LNG'nin depolanması, gazlaştırılması ve iletim hattına gönderilmesi faaliyetleri yürütülmektedir. BOTAŞ ve Ege Gaz A.Ş. tarafından gerçekleştirilen spot LNG ithalat miktarlarına göre oranlar Çizelge 2.3'te yıllar itibariyle verilmiştir (EPDK, 2015).

Çizelge 2.3 : Spot LNG ithalatı yapan şirketlerin payları (%) (EPDK, 2015).

Yıllar	EGE GAZ	BOTAŞ
2008	-	100
2009	8,5	91,5
2010	37,7	62,3
2011	13,8	86,2
2012	2,8	97,2
2013	24,6	75,4
2014	5,4	94,6

Çizelge 2.4'te ise Türkiye'nin 2005-2015 yılları arasında yapmış olduğu ithalat miktarları verilmektedir. İthalat verilerine bakıldığında, Türkiye'nin doğal gazda önemli ölçüde ithalata ve ithalatta da büyük ölçüde Rusya'ya bağımlı olduğu açıktır. Dikkat çeken diğer bir nokta ise, Spot LNG ithalatının artmasıyla birlikte Rusya'dan


yapılan ithalatın toplam ithalattaki payının, yıllar içinde %65'lerden %55'lere düşmesidir.

Çizelge 2.4 : Türkiye doğal gaz ithalat miktarları (milyon Sm³) (EPDK, 2015).

Yıllar	Rusya	İran	Azerbaycan	Cezayir	Nijerya	Diğer*	Toplam
2005	17.524	4.248	0	3.786	1.013	0	26.571
2006	19.316	5.594	0	4.132	1.100	79	30.221
2007	22.762	6.054	1.258	4.205	1.396	167	35.842
2008	23.159	4.113	4.580	4.148	1.017	333	37.350
2009	19.473	5.252	4.960	4.487	903	781	35.856
2010	17.576	7.765	4.521	3.906	1.189	3.079	38.036
2011	25.406	8.190	3.806	4.156	1.248	1.069	43.874
2012	26.491	8.215	3.354	4.076	1.322	2.464	45.922
2013	26.212	8.730	4.245	3.917	1.274	892	45.269
2014	26.975	8.932	6.074	4.179	1.414	1.689	49.262
2015	26.783	7.826	6.169	3.916	1.240	2.493	48.427

* Spot LNG ithalatının yapıldığı ülkeleri temsil etmektedir.

2015 yılında 48,4 milyar Sm³ olarak gerçekleşen toplam doğal gaz ithalatının tedarikçi ülkeler bazında dağılımı Şekil 2.8'de verilmektedir. Gerçekleşen ithalatın yarısından fazlası Rusya'dan olup, Rusya'yı İran ve Azerbaycan takip etmiştir. Toplam ithalatın %10,5'lik kısmını karşılayan LNG ithalatı ise Cezayir ve Nijerya'dan yapılmıştır.



Şekil 2.8 : 2015 yılı tedarikçi bazında doğal gaz ithalat miktarları (EPDK, 2015).

2.4.3 İhracat

Türkiye doğal gaz piyasasında doğal gaz ihracat miktarları ithalat miktarlarına göre oldukça düşük olup, yurt dışına ihraç faaliyeti ihracat lisansı almış tüzel kişiler tarafından, lisanslarında belirtilen ülkeler dâhilinde gerçekleştirilebilmektedir. İhraç edilen doğal gaz, yurt içinde üretilmiş ya da ithal edilmiş olabilir. Türkiye-Yunanistan

Doğal Gaz Boru Hattı'nın tamamlanması ile 18.11.2007 tarihinde doğal gaz ihracatına başlayan BOTAŞ'ın ihraç ettiği doğal gaz miktarları Çizelge 2.5'te verilmiştir.

Çizelge 2.5 : Türkiye doğal gaz ihracat miktarları (milyon Sm³) (EPDK, 2015).


Yıllar	2007	2008	2009	2010	2011	2012	2013	2014	2015
Miktar	30,8	435,8	708,5	648,6	714	611	682	632,6	623,9

İhracat lisansı sahibi tüzel kişilerden hali hazırda sadece BOTAŞ faaliyette bulunmakta olup Yunanistan'a doğal gaz ihraç etmektedir.

2.4.4 Toptan satış

Türkiye'deki doğal gaz toptan satış faaliyetleri, EPDK'den toptan satış lisansı almış veya mevcutta ithalat lisansı bulunan tüzel kişiler tarafından gerçekleştirilmektedir. Doğal gazın toptan satış faaliyetleri, yurt içinde üretilmiş veya ithal edilmiş doğal gazın ithalat, ihracat, dağıtım, CNG ve diğer toptan satış şirketleri ile son kullanıcı olan serbest tüketicilere satışını kapsamaktadır.

Türkiye Doğal Gaz Piyasasında BOTAŞ hakim rol üstlenmeye devam etmektedir. Şekil 2.9'da görüleceği üzere, 2015 yılında gerçekleşen 48,8 bcm (milyar Sm³) doğal gaz arzının %83 gibi büyük kısmını BOTAŞ, %16'lık kısmını ithalat lisansına sahip şirketler ve %1 gibi çok düşük kısmını da doğal gaz üretimi yapan toptan satış şirketleri karşılamıştır.



Şekil 2.9 : Botaş ve diğer şirketlerin doğal gaz arzındaki payları (EPDK, 2015).

Doğal Gaz Piyasası Kanununda öngörülen liberal piyasa modeli toptan satış faaliyeti alanında rekabetin oluşturulması temeline dayanmakta olup, bu kapsamda piyasa

oyuncu sayısının arttırılarak hâkim yapıların önlenmesi önem arz etmektedir. 2015 yılındaki boru gazı olarak toptan satış faaliyetlerini, bir kısmı doğal gaz üretimi yapan, bir kısmı ithalat yapan bir kısmı da diğer şirketlerden aldığı gazın satışını yapan toplamda 48 şirket tarafından gerçekleştirilmiştir (EPDK, 2015). Boru hatları yoluyla satışı gerçekleşen gazın yanında, kara tankerleriyle nihai tüketicilere ulaştırılan LNG'nin toptan satışı ise 2015 yılında 7 şirket tarafından gerçekleştirilmiştir. Marmara Ereğlisi ve Aliağa LNG Terminallerinden LNG formunda temin edilerek piyasaya satışı gerçekleşen gaz miktarı 2015 yılında toplam 549,5 milyon Sm³ olarak gerçekleşmiştir (EPDK, 2015).

2.4.5 İletim

Türkiye Doğal Gaz Piyasasında iletim faaliyeti serbestleşme ve özelleşmeye açılmayan tek alandır. Doğal Gaz Piyasasında sistemin güvenliği ve takibi gerekçeleriyle doğal gaz iletim faaliyetinin, yalnızca kamu tüzel kişiliği olan BOTAŞ tarafından yürütülmesine karar verilmiştir. 4646 sayılı kanun ile doğal gaz iletim faaliyetinin ticaret faaliyetinden ayrıştırılarak ayrı bir yapıda yürütülmesine yönelik düzenlemeler yapılmış olup, bu kapsamında BOTAŞ hesap ayrışmasına giderek kanun gereği iletim ve ticaret faaliyetlerini ayırtmıştır. BOTAŞ'ın dikey bütünleşikten yatay bütünleşik yapıya uygun olarak yeniden yapılandırılması sonucunda meydana gelecek yeni tüzel kişilerden iletim faaliyetini yürütecek olan şirketin yine kamu uhdesinde faaliyet göstermesi öngörülmektedir (Ünal, 2014).

BOTAŞ'ın iletim faaliyetlerini yürüten departmanın görevi; şebekeye üçüncü taraf erişiminin (Third Party Access) söz konusu olması durumunda, yani şebekenin sahibi ya da işletmecisi olan şirket dışındaki şirketlerin iletim şebekesi üzerinden gazını taşıtabilityleri, piyasaya giriş yapabilmeleri için Şebeke İşleyiş Düzenlemeleri (ŞİD) kapsamında ilgili aktörlere, eşit şartlarda hizmet vermektir.

İletim şebekesine üçüncü taraf erişimi düzenlemeye tabi kılınmış ve buna ilişkin olarak 4646 sayılı Doğal Gaz Piyasası Kanunu kapsamında Doğal Gaz Piyasası İletim Şebekesi İşleyiş Yönetmeliği yayımlanmıştır. BOTAŞ İletim Şebekesi İşleyiş Düzenlemelerine İlişkin Esaslar (ŞİD), BOTAŞ iletim şebekesi üzerinden doğal gaz taşıma hizmeti almak isteyenler (Taşıtanlar) ile şebeke operatörünün (Taşıyıcı) ilişkilerini düzenleyen genel şartlar ve hükümleri düzenlemektedir. ŞİD kapsamında; doğal gaz sistemine giriş, taşıma miktarı bildirimi ve taşıma hizmetinin

programlanması, taşıma miktarının tespiti, kesinti işlemi, sevkiyat kontrolü, sistem dengelemesi, iletişim sistemi, kapasite tahsisi, doğal gaz teslimi ve ölçüm işlemi gibi şebeke işleyişine ilişkin usul ve esaslar yer almaktadır (Ünal, 2014).

İletim sistemi operatörü BOTAŞ'a ait mevcut doğal gaz boru hatlarının toplam uzunluğu 12.561 km olup, iletim sisteminin ana kontrol merkezi Yapracık, Ankara'dadır (BOTAŞ, 2014). 2015 EPDK raporunda yer alan verilere göre, doğal gaz piyasasında faaliyet göstermekte olan ithalat ve toptan satış şirketlerince 2015 yılında iletim şebekesine 9 adet Giriş Noktası'ndan (Malkoçlar, M. Ereğlisi LNG Terminali, Durusu, Doğubeyazıt-Gürbulak, Azerbaycan-Türkgözü, EGEGAZ, TPAO Silivri, TPAO Akçakoca, TEMİ) toplam yaklaşık olarak 50,2 milyar Sm³ doğal gaz girişi yapılmıştır.


İletim faaliyeti boru hattı yoluyla yapılabilirdiği gibi, Doğal Gaz Piyasası Kanunu gereği EPDK'den lisans almak şartıyla LNG taşıma vasıtalarıyla da gerçekleştirilebilmektedir. Bu çerçevede, 2015 yılında faaliyet gösteren 10 adet iletim (LNG) lisansı sahibi tarafından toplam 691 milyon Sm³ LNG ithal edilmiştir (EPDK, 2015).

2.4.6 Dağıtım

Şehir içi doğal gaz dağıtım hizmeti, EPDK tarafından açılan ihaleyi kazanan şirkete, mahalli doğalgaz dağıtım şebekesinin mülkiyeti de dâhil olmak üzere şehrin gelişmişlik düzeyi, tüketim kapasitesi ve kullanıcı sayısı gibi hususlar dikkate alınarak EPDK tarafından belirlenecek lisans süresi için verilir (DPK). Doğal gaz iletim şebekesinin kullanım hakkı BOTAŞ'a ait olup, özel şirketler kendi iletim şebekelerini mevcut şebekeyle ara bağlantı kurma koşuluyla inşa edebilmektedir. Buradaki dağıtım şirketi, belirlenen bir şehirde doğal gazın dağıtımını ve mahalli gaz boru hattı şebekesi ile nakli faaliyetlerini yapmaya yetkili kılınan tüzel kişiyi ifade eder (DPK).

Türkiye'de doğal gazın konutlarda kullanımı ilk kez 1988 yılında Ankara'da başlamış olup ilerleyen yıllarda İstanbul, Bursa, Eskişehir ve İzmit şehirlerinde de kullanılmıştır. 2003 yılında yalnızca 6 şehirde doğal gaza erişim imkânı bulunurken zamanla doğal gaz kullanımı yaygınlaşmış ve 2015 sonu itibarıyla Türkiye'de doğal gaz arzı sağlanan il sayısı 78'e yükselmiştir. Şekil 2.10'da görüleceği gibi, Şırnak ili

için yapım çalışmaları devam ederken, Hakkâri ve Artvin bölgelerine gaz götürülmesi için yapım ihale çalışmaları devam etmektedir (EPDK, 2015).




Şekil 2.10 : Türkiye doğal gaz arzı sağlanan iller (EPDK, 2015).

Nisan 2017 tarihi itibarıyla 81 il için tüm ihaleler tamamlanmış olup, bazı şehirlerde yapım çalışmaları devam etmektedir. Böylelikle doğal gazın bütün şehirlerde kullanımı hedeflenmektedir.

2.4.7 Depolama

Depolama, doğal gaz temininin azalması veya durması sonucu meydana gelen doğal gaz açığını gidermek amacıyla doğal gazın, sıvılaştırılmış doğal gaz (LNG) veya boru gazı olarak depolanmasıdır. Tüzel kişilerin doğal gazın yer altı ve yer üstünde gaz veya LNG olarak depolanması faaliyetlerinde bulunabilmeleri için, EPDK'den lisans alması zorunludur. Şekil 2.11'de, Türkiye'de yer alan depolama tesisleri ve kapasiteleri gösterilmektedir (Url-3).

Türkiye'de yeraltı doğal gaz depolama lisansına sahip 5 şirket bulunmakta olup TPAO harici diğer depolar henüz faaliyete geçmemiştir. 2007 yılında devreye alınan TPAO'ya ait Silivri Yeraltı Doğal Gaz Depolama Tesislerindeki toplam depolama kapasitesi 2,7 Milyar Sm³ olup, bunun 2,1 Milyar Sm³'ü BOTAŞ'a tahsis edilmiştir (Url-4).



Şekil 2.11 : Türkiye doğal gaz depolama tesisleri ve projeleri (Url-3).

Yer altı depolama tesislerinin dışında, 1994 yılında devreye alınmış olan ve halen BOTAŞ mülkiyet ve işletmesinde olan Marmara Ereğlisi Terminali ile 2001 yılında İzmir Aliaga’da kurulan ve 2006 yılında işletmeye alınan Ege Gaz A.Ş. LNG Terminali bulunmaktadır.

3. TALEP TAHMİN MODELLERİ

3.1 Talep Tahmini

Talep, tüketicilerin bir ürün veya hizmeti belirli bir fiyat seviyesinden almaya hazır oldukları miktara denir (Tekin, 2009). Tahmin ise gelecek dönemlerde meydana gelebilecek olayların sonuçlarının önceden hesaplanmasıdır. Başka bir ifadeyle, geçmiş dönemlerde meydana gelmiş olay veya olayların sonuçlarını değerlendirerek gelecek dönemlerde meydana gelebilecek olayların sonuçlarını öngörebilmektir (Bağırkan, 1982).

Talep tahmininin doğru yapılması, şirket yönetiminin ya da işletmelerin kısa dönemli veya uzun dönemli hedeflerine ulaşmalarında, doğru ve stratejik kararlar alabilmelerinde önemli bir etkidir. Kuruluşlar veya şirketler geleceğe yönelik kararlar verirken doğru ve güvenilir tahminlere ihtiyaç duyarlar. Sağlıklı tahminlerin yapılabilmesi için de kullanılan tahmin yöntemlerinin bilimsel temellere dayandırılması gerekmektedir (Üreten, 2005). Fakat hangi yöntem kullanılırsa kullanılsın gerçekleşen sonuçlar genellikle tahmin değerlerinden farklılık gösterir ve tahmin sonucunda belli bir hata oranı yer alır. Bunun nedenlerinden birisi, tahmin edilecek değişkeni etkileyen faktörlerin tümünün göz önüne alınmaması, ikincisi ise öngörülemeyen tesadüfî olayların ortaya çıkmasıdır (Üreten, 2005).

Talep tahmini yapılırken izlenmesi gereken bazı aşamalar mevcuttur. Öncelikle talep tahmininde kullanılacak veriler toplanır. Bu bilgilerin, talebi etkileyen bütün faktörler ve konuyla ilgili tüm değişkenler göz önüne alınarak detaylı bir araştırma sonucu elde edilmesi gerekir (Tekin, 2009). Bilgiler toplandıktan sonra talep tahmin periyodunun tespit edilmesi gerekmektedir. Talep tahmin sonuçlarının kullanılış amacı ile periyodun uzunluğu arasında yakın bir ilişki vardır. Kısa dönemli yapılan bir tahminin uzun dönemler için de kullanılması hatalı sonuçlara neden olabilir. Veriler toplanıp tahmin dönemi belirlendikten sonra uygun tahmin yöntemi seçilir. Seçilen yöntemin uygunluğunu ve tahmin sonuçlarının doğruluğunu test etmek için, tahmin değerleriyle

gerçek değerlerin karşılaştırılması ve hatanın sistematik bir şekilde tespit edilmesi gerekir (Adıyaman, 2007).

3.2 Talep Tahmin Yöntemleri

Talep tahmin çalışmalarında kullanılan yöntemler temel olarak öznel yöntemler ve nesnel yöntemler olmak üzere ikiye ayrılır.

Öznel yöntemler matematiksel verilerden daha çok tecrübenin uygulanmasına, yargılama ve zekâyâ dayanan yöntemlerdir (Tekin, 2009). Sayısal olmayan bu yöntemlerde, yapılan tahminlerin doğruluğu çalışma alanında uzman kabul edilen bireylerin yargılama ve deneyimlerine dayanmaktadır. En çok kullanılan öznel yöntemler şöyledir:

- Yönetici tahminlerini toplama yöntemi ile işletmelerdeki tedarik, üretim, satın alma, pazarlama, finans, muhasebe gibi bölüm yöneticilerinin gerek geçmiş deneyimleri, gerekse geleceğe ilişkin sezgileri dikkate alınarak talep tahmini yapılır. Bütün yönetici ve görevlilerle tek tek görüşülerek bilgiler toplanır ve karar aşamasında bu bilgiler kullanılır. Fakat bu tahmin yönteminde kişisel değerlendirme ve sezgisel faktörler öne çıktığı için sonuçlarda hata olma ihtimali çok yüksektir. Bu yöntem istatistikî yöntemlerle birlikte kullanılarak hata oranı azaltılabilir (Tekin, 2009).
- Tüketici anketleri ile tüketicilerin kullanacakları ürün hakkındaki duygu, düşünce ve beklentileri öğrenilir. Gelen cevaplar bütün tüketicileri kapsayacak şekilde analiz edilerek talep tahmini yapılmaya çalışılır. Ortaya çıkan sonuçlara göre, değerlendirilmesi yapılan ürünün veya malın fonksiyonel, şekil ve üretim tasarımları yeniden gözden geçirilebilir; kullanıcılardan alınan olumsuz dönüşlere göre ürünün piyasaya sunulması geciktirilebilir veya hiç yapılmayabilir. Yaygın olarak kullanılan bu yöntemde, anketin uygulandığı grubun bütün tüketicileri temsil edecek şekilde doğru seçilmesi ve bu kişilerin sorulan sorulara doğru cevap vermesi gerekmektedir.
- Delphi yöntemi ile mevcut verilerin istatistiksel analiz yapmak için yetersiz kaldığı durumlarda doğru bir talep tahmini yapabilmek için tüketici grupları ve ürüne ilişkin beklentiler arasında çok iyi ilişki kurabilecek kilit uzmanların

görüşüne başvurulur. Yüz yüze görüşme yapmadan ve bir arada tartışmalar yapmadan uzman kişilerin bilgisine başvurulur ve karar verme süreci kolaylaşır (Topçu, 2013).

- Nominal grup yöntemi ile delphi yöntemine benzer şekilde sezgi ve deneyimlerine güvenilen bir uzmanlar grubu oluşturulur. Fakat delphi yönteminden farklı olarak, burada uzmanların birbirleri ile etkileşmesine ve tartışmasına izin verilmektedir (Topçu, 2013).

Sayısal tahmin (nesnel) yöntemleri ise nesnel yöntemler istatistiksel ve matematiksel verilere dayanan yöntemlerdir. Tahmini yapılacak ölçüyü etkileyen değişkenler seçildikten sonra aradaki ilişki bir matematik ifade ile temsil edilir.

3.2.1 Regresyon analizi


Regresyon (bağlanım); sözlük anlamıyla, bir şeyi başka bir şeye bağlama işi ve biçimidir. Bilimsel olarak regresyon terimi bir değişkenle başka bir (ya da birden çok) değişken arasında ilişki kurma işini ve ilişkinin biçimini anlatır (Şıklar, 2003).

Regresyon analizi, herhangi bir değişkenin (bağımlı değişken) bir veya birden fazla değişken ile (bağımsız veya açıklayıcı değişken) arasındaki ilişkinin matematiksel bir fonksiyon şeklinde yazılmasıdır. Regresyon denklemi denilen bu fonksiyon yardımıyla, bağımlı değişken ile bağımsız değişkenler arasındaki ilişkiyi kuran parametrelerin değerleri tahmin edilir (Hanke ve Reitsch, 1992). Bu değerlerin tahmin edilmesi, bağımlı değişken üzerinde geliştirilecek planlarda hangi değişkenin önem kazandığının belirlenmesine yardımcı olmaktadır. Bu sayede, bağımlı değişkende meydana gelebilecek artış ya da azalışın hangi parametreden ve ne ölçüde kaynaklandığı açıklanabilmektedir.

Regresyon analizinde bağımsız (açıklayıcı) değişken sayısı bir olduğunda basit regresyon modelinden, iki ya da daha fazla olduğundaysa çoklu regresyon modelinden bahsedilir. Örneğin, enflasyon oranıyla para arzı arasındaki ya da hem para arzı hem de kamu harcamaları arasındaki ilişkinin araştırılmasında olduğu gibi (Şıklar, 2003).

Regresyon analizinde, değişkenler arasındaki ilişkinin doğrusal olup olmadığı da önemlidir. Regresyon analizinde kullanılan modeller genellikle parametrelerine göre doğrusaldır. Parametrelerine göre doğrusallık, modeldeki tüm parametrelerin basit (birinci dereceden) olmasıdır. Diğer bir deyişle, bir parametrenin üstel durumda ya da diğer bir parametre ile çarpım veya bölüm halinde bulunmamasıdır (Şehirlioğlu, 2008).

Şekil 3.1’de gösterilen regresyon doğrusu, Y ’nin X ’e göre matematik fonksiyonunun doğrusal olduğunu göstermektedir. Ancak, Y ’nin X ’e göre gözlem noktaları ($y_1, y_2, \dots, y_n$) arasından çok sayıda doğrusal fonksiyon geçirilebilir. Bu doğrusal fonksiyonlardan en uygunu, y_i gözlem değerlerine en yakın tahmini Y_i değerini veren doğrusal fonksiyon olacaktır.



Şekil 3.1: Regresyon doğrusu (Şehirlioğlu, 2008).

Gözlemlenen değer ile tahmini değer arasındaki farklar ($y_i - Y_i$) hata terimlerini oluşturur. Hata terimleri pozitif, negatif ya da sıfır değerlerine sahip olurken, bu farkların cebirsel toplamı sıfıra eşittir (Şıklar, 2003).

$$\sum_{i=1}^n e_i = \sum_{i=1}^n (y_i - Y_i) = 0 \quad (3.1)$$

$$\sigma = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - Y_i)^2} \quad (3.2)$$

Regresyon modelinde bir bağımlı değişken ve birden çok bağımsız değişken doğrusal ilişki gösteriyorsa çoklu regresyondan söz edilir. Çok değişkenli regresyon analizinde

bağımsız değişkenler eş zamanlı olarak bağımlı değişkendeki değişimi açıklamaya çalışmaktadır. Hesaplama ve yorum bakımından tek değişkenli regresyon analizine benzemektedir fakat bazı farklılıklar vardır. Çoklu regresyon katsayısı olarak tanımlanan r , bir bağımlı değişkendeki değişim ile eşzamanlı ele alınan birden fazla bağımsız değişkendeki değişim arasındaki ilişkinin derecesini göstermektedir. Başka bir ifadeyle, bağımlı değişken ile birlikte ele alınan bir grup bağımsız değişkendeki değişimin korelasyonunun bir göstergesidir (Şentuna, 2013).

Korelasyon, iki değişken arasındaki ilişkinin derecesini ifade eden bir kavramdır. Bu ilişki ne kadar güçlüyse, oluşturulan tahminlerin doğruluğunun da o derecede artması beklenir (Üreten, 2005). x ve y ikili değerleri arasındaki doğrusal ilişkinin gücünü gösteren korelasyon katsayısı (r) aşağıdaki gibi hesaplanmaktadır (Şehirlioğlu, 2008):

$$r = \frac{n \sum xy - (\sum x)(\sum y)}{\sqrt{n(\sum x^2) - (\sum x)^2} \sqrt{n(\sum y^2) - (\sum y)^2}} \quad (3.3)$$

İki değişken arasındaki korelasyon katsayısı her zaman 1'den küçük olmaktadır.

Şimdiye kadar anlatılan doğrusal regresyon modellerinin yanında, değişkenler arasındaki ilişkiyi ifade etmede doğru denkleminin yeterli kalmadığı durumlarda kullanılan doğrusal olmayan regresyon modelleri de mevcuttur. Burada doğru denklemlerinin yerine eğri denklemleri kullanılır. Bu eğrisel modelin saptanmasında yapılabilecek en basit işlem verilerin grafiğini çizmektir. Elde edilen eğri parabolik, hiperbolik veya üstel olabilir (Çağlar, 2007).

3.2.2 Zaman serisi analizine dayanan yöntemler


Kronolojik sırayla elde edilen verilere sahip değişkenlere zaman serisi adı verilmektedir. Zaman serileri analizi, zaman içinde düzenli aralıklarla gözlemlenen verilerin istatistiksel olarak incelenmesini ve gelecek dönemlerde elde edilebilecek verilerin öngörüsünün güvenilir bir şekilde yapılabilmesini içermektedir. Geçmiş verilerin zaman içinde gösterdiği düzeni esas alan bu yöntemle, geçmiş verilere bakılarak gelecek tahmin edilmektedir (Üreten, 2005).

Bir olguya ilişkin deęiřken ya da deęiřkenlerin zaman iinde yapılan mleri ya da gzlemleri zaman serilerini oluřturur. Bir fabrikadan ihra edilen haftalık rn miktarı, bir iř yerinde meydana gelen haftalık kaza sayısı, bir lkedeki aylık enflasyon oranı gibi veriler zaman serisine rnek olarak verilebilir (Demir ve Gmřđlu, 1994).

Zaman serisi analizi yapılırken, belirli dnemlerde gzlenen talep bilgilerinin bir leđe gre sıralanarak oluřturulan talep dođrusunun belli bir dzen iinde olup olmadığına bakılır.

Yapılan gzlemler sonucu, talebin sabit olduđu, bir eđilim gsterdiđi, mevsimsel ya da dnemsel deęiřimler geirdiđi veya btn bu durumların karıřımı řeklinde dađılım gsterdiđi sonucuna varılabilir (reten, 2005).

Zaman serilerinde bir eđilimden bahsedilebilmesi iin, ortalama talep dzeyde uzun dnemli bir artıř veya dřř olması gerekmektedir. Bu eđilim, artan-azalan ya da dođrusal-dođrusal olmayan řekilde olabilir. řekil 3.2’de zamana gre deęiřebilen eřitli talep dzenlerinden dođrusal eđilim, mevsimsel deęiřimler eđrisi ile deęiřmeyen sabit talep dzeni gsterilmektedir (reten, 2005).



řekil 3.2: Zamana gre eřitli talep dzenleri (reten, 2005).

Zaman serisi analizine dayanan tahmin yntemlerinden en ok kullanılanlardan bazıları; hareketli ortalamalar yntemi, stel dzeltme yntemi ve Box-Jenkins yntemleridir.

3.2.3 Hareketli ortalama yöntemi

Talep tahmini yaparken kullanılan en basit bakış açısı, geleceğin, geçmişte olanların ortalamasına doğru eğilim göstereceğini varsaymaktır. Basit hareketli ortalama yönteminde, geçmiş dönemlere ait veriler toplanarak dönemlerin sayısına bölünür ve ortalama değer hesaplanmış olur. Bu yöntem oldukça basittir (Çağlar, 2007).

Hareketli ortalama ise her seferinde en eski değeri çıkarmak ve yeni değeri eklemek yoluyla belli sayıda döneme ait değerlerin tekrarlı olarak ortalamasının alınmasıyla elde edilir. Basit ortalamadan ayrılan yanı, seriye eklenen her yeni değer ile birlikte yeni ortalamanın hesaplanmasıdır. Hareketli ortalamalar, genel veri düzenini korumakla birlikte, verilerdeki dalgalanmaları da düzeltebilmektedir (Monks, 1996). Elde edilen ortalama değer, bir sonraki dönem için tahmin değeri olarak kullanılır.

Tepki hızı, hareketli ortalamaya alınan dönem sayısı ve her döneme verilen ağırlık ile kontrol edilir. Hareketli ortalamalar yöntemi, uzak geçmişten çok yakın geçmişe ağırlık verir ve buna dayanarak yalnızca bir dönem için tahmin yapar. Örnek olarak, Nisan Mayıs ve Haziran aylarının satış ortalamaları alınarak, üç aylık hareketli ortalama ile Temmuz ayı satış tahmini yapılabilmesi verilebilir (Üreten, 2005).

3.2.4 Üstel düzeltme yöntemi

Üstel düzeltme yöntemi, geçmiş dönem verilerine eşit ağırlık veren basit hareketli ortalamalar yöntemine benzetilmektedir. Fakat hareketli ortalamalarda, geçmiş verilere eşit ağırlık vermek yerine, en yakın geçmişteki verilerin daha fazla ağırlık taşımasını sağlayacak şekilde geçmiş veriler üstel olarak ağırlıklandırılır. Üstel terimi, verilen ağırlıkların veriler eskidikçe üstel bir şekilde azaldığını göstermektedir (Orhunbilge, 1999).

Üstel düzeltme yönteminde, düzeltme katsayısı $0 \leq \alpha \leq 1$ arası değerler alabilir. Buradaki α katsayısının kullanılması ile gerekli verilerin miktarı önemli ölçüde azaltılmaktadır. Böylelikle, hareketli ortalamalar yönteminde olduğu gibi ortalamaya dâhil edilen dönem sayısı kadar veriye ihtiyaç duyulmamakta; sadece bir önceki dönemin gerçekleşen ve tahmini talep değerleri ile içinde bulunulan dönemin tahminini yapmak mümkün olmaktadır (Üreten, 2005).

3.2.5 Box-Jenkins yöntemi

Box-Jenkins yöntemi tek değişkenli bir model olup, diğerlerine göre en son geliştirilen tahmin tekniklerinden birisidir. Kısa dönemli tahminlerde oldukça başarılı olan bu metodun uygulandığı serinin, eşit zaman aralıklarıyla elde edilen gözlem değerlerinden oluşan kesikli ve durağan bir seri olduğu kabul edilir (Çağlar, 2007). Tekniğin amacı en az sayıda parametre içeren uygun modeller elde etmektir.

Box-Jenkins yöntemlerinden önce kullanılmakta olan hareketli ortalama ve üstel düzeltme yöntemleriyle yapılan tahminler bilgisayar programlarına müdahale edilmeden otomatik elde edilirken, Box-Jenkins tekniğinde bu işlem tamamı ile otomatik değildir. Burada tahmincinin bilgi ve becerisine de ihtiyaç duyulmaktadır. Bu tahmin tekniği, çözüme adım adım gitmesi, her adımda denetlenebilmesi, istatistik testlerle sonuca ulaşması, incelenen verilerin özelliğine göre modellenenebilmesi gibi üstün özelliklerinden dolayı günümüzde en çok tercih edilen yöntemlerden biri haline gelmiştir.

Box-Jenkins modellerine zaman serileri için doğrusal filtreleme tekniği de denilmektedir. Doğrusal filtrenin özel bir çeşidi olan Otoregresif (Autoregressive) AR modelleri ilk defa Yule tarafından 1927 yılında düşünülmüştür. Diğer bir filtre çeşidi olan Hareketli Ortalama (Moving Average) MA modeli, ilk defa Shutsky tarafından 1937’de ortaya atılmıştır. Otoregresif (AR) ve Hareketli Ortalama (MA) modelinin birleşimi olan ARMA (Autoregressive-Moving Average) modeli Wold tarafından 1954 yılında geliştirilmiştir. Zaman serileri için genel model belirleme stratejisi ise G.E. Box ve G.M. Jenkins tarafından geliştirilmiştir. ARMA ve daha geneli olan Otoregresif Entegre Hareketli Ortalama Modeli (ARIMA) (Autoregressive-Integrated Moving Average) Box-Jenkins Modelleri olarak bilinmektedir (Çağlar, 2007).

3.2.6 Otoregresif hareketli ortalamalar (AR-MA) yöntemi

Otoregresif (AR) modeller bir zaman serisinin herhangi bir dönemdeki gözlem değerlerini, aynı serideki geçmiş dönemin gözlem değerlerine ve hata terimine bağlı olarak açıklayan modellerdir. AR modeli basitliği ve model katsayılarının belirlenmesinde kullanılan etkin algoritmaların varlığı sebebiyle çok kullanılan bir metottur (Barutçu, 2013). Bu modeller içerdikleri geçmiş dönem gözlem değerlerinin sayısına göre isimlendirilirler. AR modeli bir tane geçmiş gözlem değeri içeriyorsa

“birinci mertebeden”, iki tane içeriyorsa “ikinci mertebeden” ve genel olarak, p tane geçmiş dönem gözlem değeri içeriyorsa “ p ’inci dereceden” AR modeli olarak adlandırılır (Naylor ve diğerleri, 1972).

Bir rastgele $y(t)$ işareti, işaretin t anından önce aldığı değerler ve işaretle ilintili olmayan bir gürültünün $x(t)$ kombinasyonu şeklinde ifade edilmiş ve y işareti Δt zaman aralıklarıyla örneklenmiş olursa, AR modeli aşağıdaki gibi ifade edilir (Barutçu, 2013). Burada n , modelin mertebesini göstermektedir.

$$y(t) = \sum_{i=1}^n a_i y(t - i\Delta t) + x(t) \quad (3.4)$$

Çok kullanılan bu modelle ilgili istatistiksel bir problem, modelin mertebesinin belirlenmesinde ortaya çıkmaktadır. Modelin mertebesi olması gerektiğinden daha küçük seçildiğinde parametrelerin tahmini tutarlı olmamakta, olması gerektiğinden daha büyük seçildiğinde ise parametrelerin tahmininin varyansı büyük çıkmaktadır. Güvenilir, doğru sonuçlar veren bir model kurabilmek için model mertebelerini hatasız bir şekilde belirlemek gerekmektedir (Barutçu, 2013). Genelde, AR-model mertebesinin arttırılmasıyla öngörü hatası düşmektedir. En çok kullanılan model belirleme algoritmalarından biri Akaike Enformasyon Kriteri (*AIC*)’dir. Burada N örnek sayısını, n model mertebesini ve σ_x^2 öngörü hatasının varyansını göstermektedir.

$$AIC = \ln(\sigma_x^2) + \frac{2n}{N} \quad (3.5)$$

Hareketli Ortalama (MA) modelleri, herhangi bir dönemdeki gözlem değerini, zaman serisinin aynı ve ondan önceki belirli sayıda dönemdeki hata terimlerine bağlı olarak açıklayan modellerdir. MA modelleri içerdikleri geçmiş dönem hata terimi sayısına göre isimlendirilir. Modelde bir tane geçmiş dönem hata terimi varsa “birinci dereceden”, iki tane varsa “ikinci dereceden” ve genel olarak, q tane geçmiş dönem hata terimi içeriyorsa “ q ’uncu dereceden” MA modeli olarak adlandırılır (Naylor ve diğerleri, 1972).

Zaman serisinin gürültüden arındırılması ve trendin belirginleştirilmesi amaçlarıyla kullanılan bir MA modeli, n model mertebesi olmak üzere aşağıdaki gibi gösterilebilir:

$$y(t) = \sum_{i=1}^n b_i x(t - i\Delta t) + x(t) \quad (3.6)$$

Sadece AR(p) veya MA(q) süreçlerinin değil her iki sürecin de özelliklerini taşıyan durağan serilerde, bu serilerle daha iyi uyum sağlayabilecek ARMA(p,q) (Otoregresif Hareketli Ortalama) modelleri geliştirilmiştir. Zaman serilerinin modellenmesinde esneklik sağlamak ve en az sayıda parametre ilkesini gerçekleştirmek amacıyla, modele hem otoregresif hem de hareketli ortalama parametreleri alınmasının birçok yarar sağladığı düşünülmektedir. Bu düşünce ile ortaya çıkan ARMA modelleri, herhangi bir zaman serisinin herhangi bir dönemine ait geçmiş gözlem değerleri ve geçmiş hata terimlerinin doğrusal bir fonksiyonudur. AR, MA VE ARMA modelleri doğrusal durağan stokastik tahmin modelleridir (Box ve diğerleri 2008).

Yukarıda örnek olarak verilen AR ve MA modellerinin birleşmesiyle oluşan ARMA modeli ise aşağıdaki gibi gösterilir:

$$y(t) = \sum_{i=1}^n a_i y(t - i\Delta t) + \sum_{i=1}^n b_i x(t - i\Delta t) + x(t) \quad (3.7)$$

3.2.7 Otoregresif entegre hareketli ortalamalar (ARIMA) yöntemi

Bu yönteme durağan olmayan doğrusal stokastik model de denilmektedir. Uygulamalarda karşılaşılan zaman serilerinin çoğu durağan değildir. Bu serilerin durağanlığı trend, mevsimsel dalgalanma ve tesadüfi sebepler gibi etkenler tarafından bozulur. Durağan olmayan zaman serilerinin modellenmesi, seride durağanlığın sağlanmasına bağlıdır (Topçu, 2013). Durağanlığın sağlanması için, önce söz konusu etkenlerin belirlenmesi, sonra da yok edilmesi gerekir. Bir zaman serisinin gözlem değerleri bu serinin ortalama değeri etrafında durağan değilse, serinin uygun derecede farkları alınarak durağanlık sağlanır. Fark alma derecesi d ile gösterilir ve uygulamada d genellikle 1 ve en çok 2 değerini alır. Durağan olmayıp, farkı alınarak durağan hale getirilmiş serilere uygulanan modellere entegre modeller veya durağan olmayan stokastik modeller denir. Bu entegre modeller, belirli sayıda farkı alınmış serilere uygulanan AR ve MA modellerinin birleşiminden oluşur. Eğer AR modelinin derecesi p , MA modelinin derecesi q ve serinin de d kez farkı alınmışsa bu modele (p,d,q) dereceden Otoregresif Entegre Hareketli Ortalama Modeli denir ve ARIMA (p,d,q) şeklinde gösterilir (Çağlar, 2007).

4. YAPAY SİNİR AĞLARI

Yapay sinir ağları (YSA), insan beyninin öğrenme sürecine benzer bir şekilde, biyolojik nöron hücrelerinin yapısı ve öğrenme karakteristiklerinden esinlenerek geliştirilmiş olup, kısaca birlikte işleyen çok sayıda işlem elemanından (nöron) oluşan bir bilgisayar işleme ve hesaplama sistemi olarak tanımlanabilir (Haykin, 1999). Bu sistemler beynin işleme mekanizmasına iki şekilde benzemektedir (Haykin, 1999):

- Bilgi, ağa bir öğrenme prosesi ile çevresinden kazandırılır.

- Nöronlar (işlem birimleri) arası bağlama kuvvetleri olarak bilinen sinaptik ağırlıklar, edinilen bilgiyi depolamak için kullanılır.

Yapay sinir ağları, insan beyninin öğrenme sürecini matematiksel olarak modelleyerek, yeni bilgiler oluşturabilme ve keşfedebilme gibi yetenekleri herhangi bir yardım almadan, otomatik olarak gerçekleştirmeyi hedeflemektedir. Bu nedenle, konu üzerindeki ilk çalışmalar beynin nörofiziksel yapısı incelenerek nöronların modellenmesi ve bu modellerin bilgisayar sistemlerine uyarlanmasıyla başlamıştır. İlerleyen süreçte bilgisayar sistemlerinin giderek gelişmesiyle YSA'lar birçok alanda kullanılır hale gelmiştir.

4.1 Yapay Sinir Ağlarının Tarihçesi Ve Yapılan Önemli Çalışmalar

İnsan beyninin fonksiyonları ve nasıl çalıştığı uzun yıllar merak edilen bir konu olmuş ve bu konuda pek çok çalışma yapılmıştır. 1940'tan önceki yıllarda yapay sinir ağları üzerine yapılan çalışmaların mühendislik değeri olmamış, McCulloch ve Pitts gibi bilim adamlarının 1940'lı yıllardan sonra yaptığı araştırmalar sonucu günümüzdeki yapay sinir ağlarının temeli atılmaya başlanmıştır. McCulloch ve Pitts ilk yapay sinir hücresi yapısını oluşturarak, bu hücrelerle her türlü mantıksal ifadenin formülize edilebilmesinin mümkün olduğunu 1943 yılında yayınladıkları makalelerinde göstermişlerdir (Öztemel, 2012). 1949 yılında ise Donald Hebb tarafından, günümüzde de birçok öğrenme kuralının temelini oluşturan, "Hebbian öğrenme kuralı" geliştirilmiştir. 1954 yılında Farley ve Clark tarafından bir ağ içerisinde

uyarılara tepki veren ve bu uyarılara adapte olabilen bir model oluşturulmuştur. 1958 yılında Rosenblatt tarafından, çok katmanlı algılayıcıların temelini oluşturan tek katmanlı algılayıcı model (perceptron) geliştirilmiştir. İlk nöronsel bilgisayarın ortaya çıkışı ise 1960 yılında olmuştur. 1965 yılında makinelerin öğrenmesine ilişkin ilk kitap yayınlanmış ve yapay sinir ağı çalışmaları bu yıllardan sonra ancak hız kazanabilmiştir. 1970 yılı, yapay sinir ağları tarihinde önemli bir yere sahiptir. Basit modellerin eksikliklerinin fark edilmeye başlanmasıyla bu yıl önemli bir dönüm noktası olmuş ve o zamana kadar olmaz diye düşünülen birçok sorun çözülerek yeni gelişmeler başlamıştır.

1972’lerde Kohonen ve Anderson öğretmensiz öğrenme kurallarının temelini oluşturacak ilk çalışmaları yapmıştır. 1974 yılında ise, çok katmanlı algılayıcı için ilk çalışmalar yapılarak geriye yayılım modeli geliştirilmiştir. 1982 yılında, Hopfield ağları geliştirilerek yapay sinir ağlarının genelleştirilebileceği ve geleneksel bilgisayar programlama ile çözülmesi zor olan problemlere çözüm üretilebileceği gösterilmiştir (Öztemel, 2012). 1985 yılında, Delta öğrenme kuralının ve çok katmanlı algılayıcıların geliştirilmesiyle yapay sinir ağları yaygın olarak tanınmaya başlanmış ve bu yıllardan sonra pek çok çalışma ve uygulama geliştirilmiştir. Günümüzde de yoğun araştırmaların yapılmaya devam ettiği yapay sinir ağları, bilgisayar sistemlerinin gelişimine de paralel olarak birçok alanda kullanılır hale gelmiştir.

4.2 Yapay Sinir Ağlarının Genel Özellikleri

Yapay sinir ağları, gerçek beyin fonksiyonlarının ürünü olan örnekleri kullanarak olayları öğrenebilen ve çevreden gelen olaylara karşı nasıl tepkiler üretebileceğini belirleyebilen bilgisayar sistemleridir. Bu sistemler, insan beyninin fonksiyonel özelliklerine benzer bir şekilde öğrenme, ilişkilendirme, özellik belirleme, sınıflandırma, genelleme ve optimizasyon yapma gibi işlemleri başarılı bir şekilde gerçekleştirebilmektedir (Öztemel, 2012).

YSA’lar literatürde “bağlantılı ağlar”, “paralel dağıtılmış ağlar” ve “nöro bilgisayarlar” gibi isimlerle de anılmaktadır (Haykin, 1999). Bu tanımların ortak noktası ise, yapay sinir ağlarını oluşturan hücrelerin birbirine hiyerarşik olarak bağlı olması ve birbirleriyle paralel olarak çalışabilmesidir. Bütün modeller için geçerli

olabilecek genel karakteristik özellikler ise aşağıdaki gibi sıralanabilir (Öztemel, 2012).

Yapay sinir ağlarında işlemler doğrusal değildir ve bütün ağa yayılmış durumdadır. Bu paralellik özelliği sayesinde doğrusal olmayan karmaşık problemlerin de çözümlenmesi mümkündür.

Olayları öğrenerek benzer olaylar karşısında benzer kararlar vermeye çalışan yapay sinir ağlarının temel işlevi bilgisayarların öğrenmesini sağlamaktır.

Çalışma stili bilinen geleneksel programlama ve yapay zekâ yöntemlerinin uygulandığı bilgi işleme yöntemlerinden tamamen farklıdır. Bu nedenle geleneksel programlamanın getirdiği birçok olumsuzluk ortadan kaldırılabilir.

Geleneksel programlamada olduğu gibi bilgiler veri tabanları ya da dosyalarda belli bir düzende tutulmaz, ağın tamamında dağınık olarak saklanır. Hücrelerden bazılarının işlevini yitirmesi, anlamlı bilginin kaybolmasına neden olmaz. Ağın üzerinde saklı olan bilgilerin ortaya çıkartılması ve yorumlanması zordur.

Yapay sinir ağlarının örnekler olmadan eğitilmesi ve öğrenmesi mümkün değildir. YSA'nın öğrenebilmesi için örneklerin belirlenmesi, bu örneklerin ağa gösterilerek istenen çıktılara göre ağın eğitilmesi gerekmektedir. Ağın başarısı, seçilen örnekler ile doğru orantılıdır. YSA'ya olay bütün yönleri ile gösterilemezse ağ yanlış çıktılar üretebilir.

YSA'ların kendi kendine öğrenebilme ve organize etme yetenekleri vardır. YSA'lar eğitimleri sırasında kendilerine verilen örneklerden genellemeler çıkarırlar ve bu genellemeler ile yeni örnekler hakkında bilgi üretebilirler. Elde bulunan örnekler, eğitim seti ve test seti olarak ikiye bölünür. Eğitim tamamlandıktan sonra test seti ile ağın performansı ölçülür.

Bilgiye dayalı çözümlerde uzman sistemler kullanılırken, algılamaya yönelik bilgilerin işlenmesinde YSA'lar kullanılmaktadır. Yapılan uygulamalar, YSA'ların bu alanda başarılı olduklarını göstermektedir.

Bazı durumlarda, ağı eksik bilgiler içeren bir örüntü (pattern) veya bir şekil verilir ve ağın bu eksik bilgileri bulması istenir. YSA'lar kendilerine örnekler halinde verilen örüntüleri kendisi veya diğerleri ile ilişkilendirebilir. Ayrıca kendisine verilen örneklerin kümelenmesi ile bir sonraki verinin hangi kümeye dâhil olacağını karar verilmesi konusunda kullanılabilirler.

Geleneksel yöntemlerin aksine, YSA'lar eğitildikten sonra eksik bilgiler ile çalışabilir ve sonuç üretebilirler.

Yapay sinir ağlarında sembolik ifadeler ile gösterilen bilgilerin nümerik gösterime çevrilmesi gerekir. Ağlar sadece nümerik bilgiler ile çalışabilmektedirler.

Yapay sinir ağlarının eksik bilgilerle çalışabilme yeteneği, ağı ait bazı hücrelerin bozulması ve çalışamaz hale düşmesi durumunda bile ağların işleyebilmesini sağlamaktadır. Bu da onları hatalara karşı daha toleranslı yapmaktadır.

YSA'larda bilgi ağı dağılmış bir şekilde tutulur. Hücrelerin bağlantı ve ağırlık dereceleri, ağın bilgisini gösterir. Bu nedenle tek bir bağlantının kendi başına anlamı yoktur.

YSA'ların kendi kendine öğrenebilme yetenekleri vardır. Kendilerine gösterilen örneklere adapte olarak online (çevrimiçi) olarak öğrenebilirler ve kendi kendilerini eğitebilirler.

Yapay sinir ağlarında ağırlıkların yeniden yapılandırılabilir olması, belirli bir problemi çözmek için eğitilen yapay sinir ağının problemdeki değişikliklere göre yeniden eğitilebilmesini ve farklı koşullara uyarlanabilmesini sağlamaktadır.

4.3 Yapay Sinir Ağlarının Dezavantajları

Yapay sinir ağlarının pek çok avantajı olmasının yanında bazı dezavantajları da mevcuttur.

YSA'ların en önemli sorunlarından biri donanıma bağımlı olmalarıdır. Paralel işlem yapabilme yeteneği, onların seri şekilde çalışan ve aynı zamanda sadece tek bir bilgi

işleyebilen makineler ile performans göstermesini zorlaştırır. Paralel işlemleri seri makinelerde yapmak ayrıca zaman kaybı anlamına gelmektedir.

Bir diğer dezavantaj ise, yapay sinir ağlarının öğrenme süresinin uzun olmasıdır (Karahana, 2011). Bir problemin çözümü için uygun olacak ağın nasıl oluşturulması gerektiğini gösteren kurallar yoktur. Deneme yanılma yöntemiyle uygun ağ yapısının belirlenmesi zaman kaybına neden olurken optimum çözüm garantisi de vermemektedir. Denemeler sonucu uygun ağ yapısı bulunamaz ise düşük performanslı çözümlerin elde edilmesi de mümkün olmaktadır.

Uygun ağ yapısının belirlenmesinde kurallar olmadığı gibi ağın parametre değerlerinin belirlenmesinde de belli bir kural yoktur. YSA'larda öğrenme katsayısı, hücre sayısı, katman sayısı gibi parametrelerin belirlenmesinde belirli bir standart olmamakla birlikte her problem için farklı bir yaklaşım söz konusu olabilmektedir. Parametrelerin belirlenmesi kullanıcının tecrübesine bağlıdır. Her problem için ayrı ayrı değerlendirmeler yapılması gerekliliği de önemli bir dezavantajdır (Öztemel, 2012).

Öğretilecek problemin ağa gösterilme şekli de önemli bir problem olarak ortaya çıkmaktadır. Sadece nümerik bilgiler ile çalışabilen YSA'lar için problemin nümerik gösterime dönüştürülmesi şarttır. Burada belirlenecek gösterim mekanizması ağın performansını doğrudan etkileyecektir. Bu da kullanıcının tecrübesine ve yeteneğine bağlıdır (Url-5).

Ağın örnekler üzerindeki hatasının belirli bir değerin altına indirilmesi eğitimin tamamlanması için yeterli olarak değerlendirilirken, ağın eğitiminin ne zaman bitirilmesi gerektiğine ilişkin belli bir yöntem yoktur. Eğitimin tamamlanmasıyla optimum neticeler veren bir mekanizma henüz geliştirilmemiştir ve YSA ile ilgili araştırmaların önemli bir kolunu bu konu oluşturmaktadır.

YSA'lardaki davranışların açıklanamaması ise en dikkat çekici dezavantaj olup, probleme bir çözüm üretildiği zaman bunun nasıl ve neden üretildiği konusunda bir bilgi bulmak mümkün değildir. Bu da ağın verdiği sonuca olan güveni azaltıcı bir unsurdur (Öztemel, 2012).

4.4 Yapay Sinir Ağlarının Kullanıldığı Alanlar

Yapay sinir ağları, eksik bilgiler ile çalışabilme ve normal olmayan verileri işleyebilme yetenekleri sayesinde günümüzde pek çok alanda kullanılmaktadır. Yapay sinir ağlarıyla ilgili çalışmalara yıllar öncesinde başlanmış ve çeşitli alanlarda yapılan çok sayıdaki uygulamanın başarılı sonuçlar verdiği görülmüştür.

Eskiden laboratuvarlarda yürütülen ve kullanılan verilerin benzetim yolu ile elde edildiği çalışmalar, yapay sinir ağları sayesinde günlük hayatın içinden ve gerçek verilerle yapılır hale gelmiştir. Artık evimizdeki aletlerden elimizdeki cep telefonlarına kadar birçok alanda YSA uygulamalarına rastlamak mümkündür. Yapay sinir ağları uygulamaları; endüstriyel uygulamalar, finansal uygulamalar, askeri ve savunma uygulamaları, sağlık uygulamaları ve diğer alanlardaki uygulamalar şeklinde sınıflandırılabilir (Öztemel, 2012). Uygulamalar incelendiğinde ise yapay sinir ağlarının genel olarak tahmin, sınıflandırma, veri ilişkilendirme, veri filtreleme, tanıma ve eşleştirme, teşhis ve yorumlama gibi fonksiyonları gerçekleştirmek için kullanıldığı görülmektedir. YSA'ların değişik uygulama alanlarından bazılarını aşağıda yer verilmiştir.

Yapay sinir ağlarının endüstride kullanılan sayısız uygulaması bulunmaktadır. Üretim planlama ve kontrol çalışmalarındaki optimizasyon işlemleri, kimyasal proseslerin dinamik modellenmesi, otomobillerdeki otomatik rehber sisteminin geliştirilmesi, imalatatta makine bakım ve hataların teşhisi, endüstriyel bir proseste fırınların ürettiği gaz miktarının tahmini, işlerin makinelere atanması ve çizelgeleme gibi daha pek çok örnek endüstriyel uygulamalar için verilebilir.

Arıza analizi ve tespiti de diğer önemli uygulama alanıdır. Bir sistemin, cihazın ya da elemanın düzenli çalışma şeklini öğrenen bir nöron ağı yardımıyla, bu sistemde meydana gelebilecek arızaların önceden belirlenmesi mümkündür. Bu amaçla yapay sinir ağları; elektrikli makinelerin, uçakların, tümleşik devrelerin, vs. gibi elektronik ekipmanların arıza analizinde kullanılmaktadır (Öztemel, 2012).

Yapay sinir ağlarının insan beyninin çalışma şekliyle yakından ilgilenmesi, tıp ve sağlık alanında da pek çok uygulamanın geliştirilmesini sağlamıştır. Tıbbi işaretlerin analizi, kanserli hücrelerin belirlenmesi, solunum hastalıklarının teşhisi, hastalıkların teşhisi ve resimlerden tanı yapılması, anne karnındaki çocukların kalp atışlarının

izlenmesi, hastane giderlerinin optimizasyonu gibi pek çok faydalı YSA uygulaması mevcuttur (Karahan, 2011).

Finans alanında oldukça yaygın olarak kullanılan ve önemli işleve sahip olan YSA uygulamalarına ise, makroekonomik tahminler, indekslerin tahmin edilmesi, kredi kartı kurumlarında iflas tahminleri, banka kredilerinin değerlendirilmesi, emlak kredilerinin yönetilmesi, döviz kuru tahminleri, risk analizleri gibi örnekler verilebilir.

Yapay sinir ağlarının sivil hayattaki uygulamaları kadar, askeri alandaki uygulamaları da dikkat çekmektedir. Silahların otomasyonu ve hedef izleme, hedef tanıma ve takip sistemleri, radar ve görüntü işaretlerinin işlenmesi, askeri uçakların uçuş yörüngelerinin belirlenmesi, mayın detektörleri, gürültü giderme gibi uygulamalar bunlardan bazılarıdır.

Yapay sinir ağları gerçek hayatta karşılaşılan problemlerde oldukça geniş bir uygulama alanı kazanmıştır. Yukarıda verilen uygulama alanları bunlardan sadece bazılarıdır. Yapay sinir ağlarının potansiyel uygulama alanları ise, insan zekâsının kolaylıkla üstesinden geldiği fakat bazı teknik sorunlar yüzünden klasik bilgisayarların çok yavaş veya yetersiz kaldığı durumlar olarak tarif edilebilir.


4.5 Yapay Sinir Ağlarının Yapısı ve Temel Elemanları

4.5.1 Biyolojik sinir hücresi

Yapay sinir ağları biyolojik sinir sistemlerinden esinlenerek geliştirilmiştir. İnsan beyninin çalışma prensibini temel alan yapay sinir ağlarının daha iyi anlaşılabilmesi için biyolojik sinir ağlarının yapısının ve çalışma ilkelerinin iyi bilinmesi gerekir. İnsanların bütün davranışlarını ve çevresini anlamasını sağlayan sinir sistemi, birbiri ile iletişim halinde olan sinir hücrelerinden oluşmaktadır.

Bir sinir ağı, nöron adı verilen milyarlarca sinir hücresinin bir araya gelmesi ile oluşmaktadır. Birbirleriyle bağlantılı olan bu hücrelerde, sinyaller çok karmaşık elektro-kimyasal olaylar zinciriyle oluşan ve sayısı saniyede 1000 taneye kadar çıkabilen titreşimler halinde iletilmektedir (Karahan, 2011).

Biyolojik sinir sisteminin en temel yapı taşı olan nöronların yapısı, Şekil 4.1’de gösterildiği üzere dendrit, akson, çekirdek ve bağlantılar olmak üzere dört ana bölümden oluşmaktadır.



Şekil 4.1: Biyolojik sinir hücresinin (nöron) yapısı (Fausett, 1994).

Sinir hücresinin ucunda bulunan ağaç kökü görünümüne sahip dendritlerin görevi, bağlı olduğu diğer nöronlardan veya duyu organlarından gelen sinyalleri çekirdeğe iletmektir. Dendritten gelen sinyaller çekirdekte toplanarak sinir hücresinin binlerce dala ayrılan ince ve uzun ayakları olan aksonlara iletir. Toplanan bu sinyaller akson tarafından işlenerek nöronun diğer ucunda bulunan bağlantılara (sinapsis) gönderilir. Sinapsisler sinir hücreleri arasındaki bağlantılar olup, bir hücreden diğerine elektrik sinyallerinin geçmesini sağlayan boşluklardır. Aksonlardan alınan sinyaller sinaptik bağlantılarda nörotransmitterler yolu ile diğer nöronlara iletilir ve bilgi alış verişi sağlanır (Fausett, 1994). Özetle, nöronlar çevreden gelen uyarıları alarak yorumlayan ve bunları uygun çıktılara dönüştürmek üzere işleyen, beynin en temel yapı taşlarıdır.

4.5.2 Yapay sinir hücresi


Yapay sinir hücreleri de biyolojik sinir hücrelerine benzer yapıdadır. Yapay nöronlar da aralarında bağ kurarak yapay sinir ağlarını oluştururlar. Yapay sinir ağları metodolojisine göre, biyolojik sinir sisteminin temel işlem birimi olan nöronlar, matematiksel olarak modellenebilirler ve biyolojik sinir sistemlerinde olduğu gibi

birbirleriyle ilişkilendirilebilirler. Aynı biyolojik nöronlarda olduğu gibi yapay nöronların da giriş sinyallerini aldıkları, bu sinyalleri toplayıp işledikleri ve çıktıları ilettikleri bölümleri bulunmaktadır.

Yapay sinir ağları biyolojik sinir ağlarının taklit edildiği matematiksel modellemelerdir. Bir yapay sinir ağına dışarıdan veri girişi yapıldığında, insanlardaki sinir sisteminde olduğu gibi girdileri yapay nöronlarda isler ve çıktılar üretebilir. Başlangıçta üretilen çıktı değerleri istenenden oldukça uzak olabilir, fakat öğrenme işlemi devam ettikçe yapay nöronlar arasındaki sinaptik ağırlıklar ayarlanarak belirli bir yakınsama sağlanır ve öğrenme tamamlanır (Karahan, 2011).

Günümüzdeki yapay sinir ağlarının temeli, McCulloch ve Pitts tarafından 1940'lı yıllardan sonra atılmaya başlanmıştır. McCulloch ve Pitts ilk yapay sinir hücresi yapısını oluşturarak, bu hücrelerle her türlü mantıksal ifadenin formülize edilebilmesinin mümkün olduğunu göstermişlerdir (Öztemel, 2012).

Şekil 4.2'de 1943 yılında McCulloch ve Pitts tarafından geliştirilen nöron modeli gösterilmektedir (Barutçu, 2013). Bu yapay sinir hücresi, girdilerin ağırlıklı toplamının eşikten geçtikten sonraki değeri ile karşılaştırılması sonucuna göre çıktı üreten bir çalışma prensibine sahipti.



Şekil 4.2: McCulloch-Pitts nöron modeli (Barutçu, 2013).


Bu modelde eğer ağırlıklı toplam eşik değerinden büyük ya da eşit değerine eşitse hücrenin çıktısı 1, aksi durumda 0'a eşit olmaktadır (Hamzaçebi, 2011). Fakat bu hücrelerin öğrenme yeteneği yoktu, ağırlık değerleri karar verici tarafından belirlenmekteydi 1950'li yılların sonlarında Frank Rosenblatt ve daha birçok araştırmacı, algılayıcı adını verdikleri sinir ağlarını geliştirdi. Bu ağlardaki nöronların McCulloch-Pitts yapay sinir hücresinden farkı, nöron hücresinin eğitimi için bir

öğrenme kuralının geliştirilmiş olmasıdır (Hamzaçebi, 2011). Algılayıcı, YSA'ların en basit biçimidir. Algılayıcılar tek katmanlı ve çok katmanlı algılayıcılar olarak ikiye ayrılırlar:

Tek katmanlı algılayıcılar (TKA), sadece girdi ve çıktı katmanlarından oluşur. Ağırlıklandırılmış girdi değerlerinin toplanıp eşikten geçirilmesi sonucu bulunur. Bilinen en önemli tek katmanlı algılayıcılar, basit tek katmanlı algılayıcılar (perseptron), ADALINE ünitesi ve birden fazla ADALINE ünitesinin bir araya gelerek oluşturdukları MADALINE üniteleridir. Tek katmanlı algılayıcıların en önemli problemi, doğrusal olmayan olayları öğrenememeleridir (Öztemel, 2012).

TKA'lar ve ilk geliştirilen YSA'lar doğrusal olan olayları çözebilme yeteneğine sahipken, bu ağlar ile doğrusal olmayan olaylar öğrenilememektedir. Çok katmanlı algılayıcılar (ÇKA) bu problemi ortadan kaldırmak için geliştirilmişlerdir. ÇKA ağlarının yapısı ileriye doğru bağlantılı üç katmandan oluşur. Girdi katmanından ağırlıklı olarak ara katmanlardan geçerek çıktı katmanına geçer ve gelen bilgilere karşılık ağırlıklandırılmış girdi dış dünyaya iletilir. ÇKA ağı öğretmenli öğrenme stratejisini kullanır (Öztemel, 2012).

Şekil 4.3'te, basit YSA'ların geliştirilmesiyle oluşturulan modern nöron modeli gösterilmektedir (Barutçu, 2013).



Şekil 4.3: Modern nöron modeli (Barutçu, 2013).

Modelde yapay sinir hücrelerinin temel yapı elemanları ve katmanlardaki matematiksel fonksiyonlar yer almaktadır. Her bir girdideki değişim, nöron çıkışında belirli bir değişime neden olmakta ve bu değişimin büyüklüğü girdinin ağırlık derecesine bağlı olmaktadır. Mühendislik biliminde proses elemanı olarak da adlandırılan Yapay sinir hücreleri, en temel haliyle girdiler, ağırlıklar, toplama fonksiyonu, aktivasyon fonksiyonu ve çıkış olmak üzere beş bileşenden oluşur.


Girdiler, yapay sinir hücresine dış dünyadan gelen bilgilerdir. Bilgiler dış dünyadan gelebildiği gibi, başka hücrelerden veya kendisinden de gelebilir (Öztemel, 2012). Girdiler, yapay sinir ağlarının algılayıcılarıdır. Veri üzerinde hiçbir matematiksel işlem yapmadan sadece iletilici görevi yaparlar ve verileri bir sonraki aşamaya iletirler.

Ağırlıklar, bir yapay hücreye gelen bilginin önemini ve hücre üzerindeki etkisini gösterir. Şekil 4.3'te olduğu gibi, ağırlık değeri w_1 , x_1 girdi değerinin hücre üzerindeki etkisini göstermektedir. Ağırlıkların tüm işlem elemanları üzerinde etkili olması için, girdiler ile nöronlar arasında iletişimi sağlayan bütün bağlantıların değişik ağırlık değerlerinin olması gerekmektedir. Ağırlıklar değişken veya sabit değerler olabilmektedir. Başlangıç değerleri genellikle -1 ile +1 aralığında rastgele seçilmektedir. Ağlardaki öğrenme işlemi, ağırlıkların değiştirilmesiyle sağlanır. Ağırlıklar, biyolojik nöron hücresindeki sinaptik membranların geçirgenliği olarak düşünülebilir (Öztemel, 2012; Karahan, 2011).

Toplama fonksiyonu, biyolojik sinir hücresindeki hücre çekirdeğinin yaptığı görevi yapan fonksiyondur ve hücreye gelen net girdiyi hesaplar. Bunun için kullanılan değişik fonksiyonlar olsa da en yaygın olarak kullanılan fonksiyon ağırlıklı toplama fonksiyonudur. Yapay sinir hücresine gelen girdi değerleri ağırlıklarıyla çarpılarak toplanır ve ağa gelen net girdi bulunmuş olur (Öztemel, 2012).

Bazı durumlarda gelen girdilerin değeri dikkate alınırken bazı durumlarda ise gelen girdilerin sayısı önemli olabilmektedir. Bir problem için en uygun toplama fonksiyonu belirlenirken geliştirilmiş bir yöntem yoktur. Genellikle deneme yanılma yoluyla toplama fonksiyonu belirlenmektedir. Bazen her hücrenin toplama fonksiyonunun aynı olması gerekmez. Bu konulara karar vermek tasarımcıya aittir (Url-5).

Aktivasyon fonksiyonu, toplama fonksiyonundan gelen net girdiyi işleyerek, hücrenin bu girdiye karşılık üreteceği çıktıyı belirler. Aktivasyon fonksiyonunda da toplama fonksiyonunda olduğu gibi çıktıyı hesaplamak için değişik formüller kullanılır. Şekil 4.4'te farklı aktivasyon fonksiyonu örnekleri verilmiştir (Barutçu, 2013). Aktivasyon fonksiyonunda, ağın işlemci elemanlarının hepsinin aynı fonksiyonu kullanması gerekmez. Bazı elemanlar aynı fonksiyonu, diğerleri farklı fonksiyonları kullanabilirler.



Şekil 4.4: Aktivasyon fonksiyonu örnekleri (Barutçu, 2013).

Tasarımcı, yaptığı denemeler sonucunda problem durumuna en uygun fonksiyonu kendisi belirleyebilir. Aktivasyon fonksiyonu olarak hangi fonksiyonun seçileceği nöron ağının verilerine ve ne öğretilmek istendiğine göre değişmektedir (Karahana, 2011). Günümüzde yaygın olarak kullanılan Çok Katmanlı Algılayıcı modelinde aktivasyon fonksiyonu olarak genellikle sigmoid fonksiyonu kullanılmaktadır (Öztemel, 2012).

Hücre çıktısı ise aktivasyon fonksiyonu tarafından belirlendikten sonra dış dünyaya veya başka bir hücreye gönderilecek çıktı değeridir. Üretilen çıktı değeri, hücrenin kendisine girdi olarak da gönderilebilir. Ağ şeklinde gösterildiğinde proses elemanının birden fazla çıktısı varmış gibi görülse de proses elemanından çıkan tek bir çıktı değeri vardır (Öztemel, 2012).

4.6 Biyolojik Ve Yapay Sinir Ağlarının Karşılaştırılması

Yapay sinir ağları biyolojik nöron sisteminden etkilenerek geliştirilmiştir. Günümüzde pek çok çalışmaya konu olsa da beyin ve nöron sisteminin tüm özellikleri ve nasıl çalıştığı henüz tam olarak bilinmemektedir. Ancak, bilgisayarlarda yaşanan gelişmeler ile insan beyninin ve nöron sisteminin anlaşılması konusunda önemli aşamalar kaydedilmiş ve belli bir düzeyde nöron sistemini taklit eden modeller tasarlanmaya başlanmıştır. Çizelge 4.1’de, biyolojik nöron hücresinin elemanlarına karşılık gelen yapay sinir hücresi elemanları gösterilmektedir (Karahana, 2011).

Çizelge 4.1 : Biyolojik ve yapay sinir ağlarının karşılaştırılması (Karahana, 2011).

Biyolojik Sinir Ağı	Yapay Sinir Ağı	Görevi
Dendrit	Alicı	Çevreden gelen veriyi alır
Akson	Verici	Gövdenin oluşturduğu veriyi iletir
Hücre Gövdesi	Toplayıcı ve Aktivasyon Fonksiyonu	Gelen veriyi toplayarak yorumlar ve çıktıyı oluşturur
Sinaptik Ağırlıklar	Bağlantı Ağırlıkları	Öğrenilenleri hafızada saklar

Görüldüğü gibi, insanlardaki nöron sisteminde bulunan her elemanın yapay sinir sisteminde de bir karşılığı tasarlanarak yapılabildiğince taklit edilmeye çalışılmıştır.

4.7 Yapay Sinir Ağlarının Yapısı

Daha önce de anlatıldığı gibi, yapay sinir hücreleri bir araya gelerek yapay sinir ağlarını oluştururlar. Genel çalışma prensibi girdi setini (örnekleri) alarak çıktı setine çevirmek olan yapay sinir ağlarının doğru çıktıyı üretebilmesi için eğitilmesi gerekir.


Yapay sinir ağları için, birbirine bağlanmış birçok basit işlemci elemanın yapılan veri girişlerinden çıktılar üretebildiği Kara Kutu benzetmesi de yapılmaktadır Şekil 4.5’te gösterildiği gibi kara kutu, dışarıdan bilgileri alıp, dışarıya ürettiği çıktıları verir ve içeride neler olduğu bilinmez. Kara kutu benzetmesinden de anlaşıldığı gibi, yapay sinir ağının sonuçları nasıl oluşturduğunu açıklama yeteneği yoktur.



Şekil 4.5: Yapay sinir ağlarının kara kutu benzetmesi (Öztemel, 2012).

Bu kara kutunun işlevi, basitçe matematiksel bir fonksiyonu temsil etmektedir. Fakat YSA bu fonksiyonun tam olarak matematiksel karşılığına ihtiyaç duymaz, çünkü ihtiyacı olan şey örneklerdir. Başka bir deyişle, modelin öğrenmeyi gerçekleştirmesi için geçmiş ile ilgili örneklerin olması yeterlidir. Yalnız burada kullanılan örneklerin bilgisayarın öğrenmesi istenen ilişkileri doğru şekilde temsil etme özelliklerinin olması gerekmektedir. Problemin ağa gösterim şekli, ağın sahip olduğu topolojik yapı, ağın kullandığı öğrenme stratejisi ve öğrenme kuralı, ağın bilgi toplama ve sonuç üretme mekanizmalarının seçimi ve ağın performansı üzerinde etkili olacaktır (Toktaş ve Aktürk, 2004).

Yapay sinir ağını oluşturan hücreler, üç tabaka halinde ve her tabaka içinde paralel olarak bir araya gelerek ağı oluştururlar. Şekil 4.6'da bir veya birden fazla gizli tabakadan oluşan YSA örnekleri gösterilmiştir (Barutçu, 2013).



Şekil 4.6: YSA'yı oluşturan tabakalar (Barutçu, 2013).

YSA'lar her ne kadar birden çok gizli tabaka içerebilirlerse de, teorik olarak ispatlanmıştır ki yeterince nörona sahip tek gizli tabaka birden çok gizli tabakanın yaptığı işi yapabilir (Barutçu, 2013). Bu nedenle bu çalışmada da tek gizli tabakalı


yapay sinir ağı kullanılmıştır. YSA'yı oluşturan tabakaları aşağıdaki gibi açıklamak mümkündür:

Giriş tabakası, en az bir girdi elemanının bulunduğu bölümdür. Bu tabakadaki proses elemanları dış dünyadan bilgileri alarak ara tabakalara transfer etmekle sorumludur. Ağlarda genellikle girdi tabakasında herhangi bir bilgi işleme olmaz (Öztemel, 2012).

Gizli tabaka, giriş tabakasından gelen bilgilerin işlenerek çıkış tabakasına gönderildiği kısımdır. Seçilen ağ yapısına göre işlem yapılan tabakanın yapısı ve fonksiyonu da değişebilir (Karahana, 2011). Gizli tabaka tek bir tabakadan oluşabileceği gibi, birden fazla tabakadan da oluşabilir.

Çıkış tabakası, gizli tabakadan gelen bilgilerin işlenerek, giriş tabakasında sunulan girdi seti için oluşturulması gereken çıktıyı üretir. Üretilen çıktı bilgileri buradan dış dünyaya iletilir.

Şekil 4.7'de, örnek bir yapay sinir ağı gösterilmiştir. Birbirine hiyerarşik olarak bağlı ve paralel olarak çalışabilen yapay sinir hücreleri bir araya gelerek YSA'yı oluşturur.




Şekil 4.7: Bir yapay sinir ağı örneği (Öztemel, 2012).

Proses elemanları da denilen bu nöronların birbirlerine bağlandıkları ve her bağlantının bir değeri olduğu kabul edilmektedir (Öztemel, 2012). Bu bağlantıların ağırlık değerleri öğrenme sırasında belirlenmektedir. Ağa verilen ilgili örneklerle eğitilerek, ağın genelleme yapabilmesi ve girdi setine karşılık gelen çıktı setini

oluşturabilmesi öğrenme işlemi olarak adlandırılır. Öğrenmenin nasıl gerçekleştiği ve ağırlıkların nasıl belirlendiği ilerleyen bölümlerde anlatılacaktır.

4.8 Yapay Sinir Ağlarının Sınıflandırılması (YSA Mimarisi)

Nöron hücrelerinin birbirlerine çeşitli şekillerde bağlanması ile yapay sinir ağları oluşur. Hücrelerin bağlantı şekillerine, öğrenme kurallarına ve aktivasyon fonksiyonlarına göre çeşitli modeller geliştirilmiştir. Pek çok nöronun bir araya gelmesi ile oluşan yapay sinir ağları belli topolojilerle (mimariler) tanımlanabilir. Şekil 4.8’de bu mimarilerden en yaygın kullanılanlar gösterilmiştir (Kartalopoulos, 1996).




Şekil 4.8: Çeşitli YSA mimarileri (Kartalopoulos, 1996).

Yapay sinir ağları tek tabakalı olabildiği gibi, birden fazla tabakaya da sahip olabilir. YSA mimarilerine bakıldığında genel olarak, istenen çıkışı elde etmek için oluşturulan bir giriş tabakası, çıkışların elde edildiği bir çıkış tabakası ve giriş-çıkış tabakaları arasında en az bir gizli tabaka bulunmaktadır. Arada bulunan gizli tabaka, dış ortamla bağlantısı olmayan nöronlardan oluşur ve bu nöronlar girdi tabakasındaki işaretleri çıktı tabakasına gönderir (Tolon ve Tosunoğlu, 2008). Ağdaki gizli tabaka sayısı bir ya da daha fazla olmalıdır. Çünkü çıktı değeri gizli tabaka olmadan direkt olarak elde edilemez (Kartalopoulos, 1996).

Yapay sinir ağı, işleyiş şekillerine göre ileri beslemeli (feedforward) ve geri beslemeli (feedback) olmak üzere iki farklı yapıda incelenebilir.

4.8.1 İleri beslemeli yapay sinir ağı

İleri beslemeli yapay sinir ağlarında işaretler sadece tek bir yönde, giriş tabakasından çıkış tabakasına doğru yönelir. Bir tabakadan elde edilen çıktı değeri, aynı tabakadaki nöronları etkilemez. Şekil 4.9’da ileri beslemeli ve farklı mimarilere sahip yapay sinir ağı örnekleri gösterilmiştir.



Şekil 4.9: Çeşitli ileri beslemeli yapay sinir ağı mimarileri (Barutçu, 2013).

İleri beslemeli ağlarda, nöronlar yalnızca bir sonraki tabakada bulunan nöronlarla bağlantıya sahiptir. Şekil 4.9’da verilen örneklerde de olduğu gibi aynı tabaka içindeki nöronların asla birbirleriyle bağlantısı olmaz (Barutçu, 2013). Bu modellerde ağın çıktısı, tamamen ağa giren girdilere bağlıdır. İleri beslemeli ağlar herhangi bir dinamiklik özelliği taşımazlar ve gösterdikleri özellik bakımından doğrusal ve doğrusal olmayan kararlı problem alanlarında uygulanmaları mümkündür (Tolon ve Tosunoğlu, 2008).

4.8.2 Geri beslemeli yapay sinir ağı

İleri beslemeli ağlarda nöronlar yalnızca bir sonraki tabakada bulunan nöronlarla bağlantılıyken, geri beslemeli ağlarda bir tabaka üzerinde yer alan nöronlar,

kendisinden, tabakadaki diğer nöronlardan ya da diğer tabakalardaki nöronlardan işaret alabilmektedir. Bu sebeple geri beslemeli ağlarda bir nöronun çıkışı, nöronun o andaki girdileri ve ağırlık değerleriyle belirlenmesinin yanında bazı nöronların bir önceki süredeki çıkış değerlerinden de etkilenmektedir (Tolon ve Tosunoğlu, 2008). Bir tür geri besleme işleminin olduğu bu ağ yapılarında işaretin yönü yine girdi tabakasından çıktı tabakasına doğrudur.

4.9 Yapay Sinir Ağlarında Öğrenme Stratejileri


Öğrenme kavramı, zaman içinde yeni bilgilerin keşfedilmesi yoluyla davranışların iyileştirilmesi süreci olarak tanımlanmaktadır (Simon, 1983). Öğrenme işinin bilgisayarlar tarafından gerçekleştirilmesi, herhangi bir olay hakkında bilgi ve tecrübeleri öğrenerek gelecekte oluşacak benzer olaylar hakkında karar verebilmesi ile olmakta olup buna makine öğrenmesi denmektedir. Bilgisayarların problemlere çözüm üretebilmesi, bilgisayarın ilgili olay hakkında bilgiler ile donatılmasına bağlıdır. Yapay sinir ağları yolu ile öğrenen bilgisayarların bilgiler ile donatılması, örnekler ile sağlanır (Öztemel, 2012).

Örneklerden öğrenmenin temelinde, herhangi bir olay hakkında verilen gerçekleşmiş örneklerle bakarak ilgili olayın girdi ve çıktıları arasındaki ilişkileri öğrenmek ve daha sonra oluşacak yeni örneklerin çıktılarını belirlerken bu ilişkileri kullanmak yatmaktadır. Burada bilgisayara örnekler dışında herhangi bir ön bilgi verilmemektedir. Farklı örneklerin kullanılmasıyla olayın değişik açılardan öğrenilmesi sağlanmaktadır. Burada öğrenmeyi gerçekleştirecek sistem, örnekler ile verilen olaydaki ilişkileri kendi algoritmasını kurarak keşfetmektedir. Yapay sinir ağları gibi örneklerden öğrenen sistemlerde, değişik öğrenme stratejileri kullanılmakta ve kullanılan öğrenme algoritması da bu stratejilere bağlı olarak değişmektedir. Uygulanan öğrenme stratejileri genel olarak üçe ayrılmaktadır (Öztemel, 2012).

4.9.1 Eğitici (supervised) öğrenme

Öğrenen sistemin olayı öğrenebilmesi için bir eğitici yardımcı olmaktadır. Şekil 4.10'da gösterildiği gibi, öğrenilmesi istenen olay ile ilgili örneklerin girdi değerleriyle, bu girdiler karşılığında oluşturulması gereken çıktı değerleri eğitici tarafından sisteme verilir. Sistemin görevi, girdileri eğiticinin belirlediği çıktılara


haritalamak ve bu sayede girdiler ile çıktılar arasındaki ilişkileri öğrenmektir (Masters, 1993). “Çok Katmanlı Algılayıcılar (ÇKA)” bu stratejiyi kullanan ağlara örnek olarak verilebilir.



Şekil 4.10: Eğitici öğrenme (Masters, 1993).

4.9.2 Destekleyici (reinforcement) öğrenme

Eğitici öğrenmede olduğu gibi, bu stratejide de öğrenen sisteme bir eğitici yardımcı olur. Şekil 4.11’de destekleyici öğrenmeye örnek gösterilmiştir.




Şekil 4.11: Destekleyici öğrenme (Masters, 1993).

Bu öğrenme şeklinde, eğitici girdi seti için olması gereken çıktı setini sisteme göstermek yerine, sistemin kendisine gösterilen girdilere karşılık kendi çıktısını üretmesini bekler ve üretilen çıktının doğru ya da yanlış olduğunu gösteren bir işaret

 retir. Sistemin  ğrenme s reci, eğitici­den gelen bu iřareti dikkate alarak devam eder (Masters, 1993). “LVQ” ağı bu sistemlere  rnek verilebilir.

4.9.3 Eğıticisiz (unsupervised)  ğrenme

Daha  ok sınıflandırma problemleri i in kullanılan bu stratejide, sistemin  ğrenmesi i in herhangi bir eğıtici yoktur. řekil 4.12’de olduėu gibi, sisteme sadece girdi deėerleri g sterilerek, n ron ağıının  rneklerdeki parametreler arasındaki iliřkileri kendi kendisine  ğrenmesi beklenir (Masters, 1993). Sistemin  ğrenmesi bittikten sonra  ıktıların ne anlama geldiėi kullanıcı tarafından belirlenmelidir. En yaygın olarak “Kohonen Ağıları” ve “ART Ağıları” yapay sinir ağı modellerinde kullanılır.



řekil 4.12: Eğıticisiz  ğrenme (Masters, 1993).

Anlatılan    temel y ntemin yanında, bu  ğrenme y ntemlerinin birlikte kullanılarak kısmen eğıticilili ve kısmen eğıticisiz olarak  ğrenme yapan ağılar da bulunmaktadır. “Radyal Tabanlı Yapay Sinir Ağıları (RBN)” ve “Olasılık Tabanlı Yapay Sinir Ağıları (PBN)” karma  ğrenme y ntemine  rnek verilebilir ( ztemel, 2012).

4.10 Yapay Sinir Ağılarında  ğrenme Kuralları

Yapay sinir ağılarında, farklı  ğrenme stratejilerine g re geliřtirilmiř  ğrenme kuralları vardır. Bu kuralların bazıları  evrimi i bazıları da  evrimdışı eğıtim yapar.

 evrimi i  ğrenme kuralları ger ek zamanlı  alıřabilmekte olup, bu kuralla  alıřan sistemler bir yandan  ğrenirken bir yandan da fonksiyonlarını yerine getirirler. Kohonen  ğrenme kuralı ve ART ağıının  ğrenme kuralı  evrimi i  ğrenmeye  rnek olarak verilebilir.

Çevrimdışı öğrenme kuralı ise test verisi ile eğitime temeline dayanmaktadır. Bu sistemler kullanıma alınmadan önce örnekler üzerinde eğitilmekte ve gerçek hayatta kullanıma alındığında ise artık öğrenme olmamaktadır. Yeni bilgiler geldiğinde, sistemin tekrar kullanıma alınabilmesi için çevrimdışı olarak yeniden eğitilmesi gerekmektedir. “Delta Öğrenme Kuralı” bu tür öğrenmeye örnek olup yapay sinir ağlarında yaygın olarak kullanılmaktadır.

Sinir ağlarında öğrenme işlemi, çok parametrelili, karmaşık ve matematiksel olarak ifade edilmesi zor bir işlemdir. Kullanılan değişik öğrenme kurallarının çoğu Hebb kuralına dayanmakta olup, temelde dört farklı algoritma vardır. Bunlar; Hebb, Hopfield, Delta ve Kohonen öğrenme kurallarıdır (Öztemel, 2012).

4.10.1 Hebb öğrenme kuralı

1949 yılında geliştirilen Hebb kuralı, bilinen en eski öğrenme kuralı olup diğer kuralların temelini oluşturmaktadır. Hebb öğrenme kuralına göre, öğrenme işareti hücre çıkışına eşittir, yani bir hücre aktif ise bağlı olduğu hücreyi aktif, pasif ise bağlı olduğu hücreyi pasif yapmaya çalışmaktadır (Adıyaman, 2007). Bu durumda, yapay sinir ağı elemanı olan hücre diğer bir hücreden bilgi alırsa ve her iki hücre de aktifse (matematik olarak aynı işareti taşıyorsa) bu iki hücrenin arasındaki bağlantı kuvvetlendirilmelidir (Öztemel, 2012).

4.10.2 Hopfield öğrenme kuralı

Hebb kuralına benzeyen bu kuralda yapay sinir ağındaki elemanların bağlantılarının nasıl değişeceği belirlenir. Ağırlıkların kuvvetlendirilmesi ya da zayıflatılması öğrenme katsayısı yardımı ile olur. Öğrenme katsayısı genellikle 0 ile 1 arasında değişen ve kullanıcı tarafından atanan sabit ve pozitif bir değerdir. Eğer beklenen çıktı ve girdilerin ikisi de aktif ise öğrenme katsayısı kadar ağırlık değerleri kuvvetlendirilir; eğer girdi ve çıktıların ikisi de pasif ise ağırlık değerleri öğrenme katsayısı kadar zayıflatılır.

4.10.3 Delta öğrenme kuralı

Widrow ve Hoff tarafından geliştirilen bu kural, Hebb kuralının biraz daha gelişmiş şeklidir. Bu kurala göre, yapay sinir hücresinin gerçek çıktısı ile beklenen çıktısı arasındaki farkı en aza indirmek için nöron ağındaki elemanları arasındaki bağlantı

ağırlık değerleri sürekli değiştirilir. Değiştirme işlemi ağın ürettiği çıktı ile üretilmesi gereken (beklenen) çıktı arasındaki hata kareleri ortalaması en aza inene kadar devam eder (Karahana, 2011).

4.10.4 Kohonen öğrenme kuralı

Kohonen tarafından geliştirilen bu kurala göre, YSA elemanları ağırlıklarını değiştirmek için birbirleri ile yarışır (Öztemel, 2012). Kazanan hücrenin bağlantı ağırlıklarının değiştirilmesi demek, o hücrenin yakınındaki hücrelere karşı daha kuvvetli hale gelmesi demektir. En büyük çıktıyı üreten eleman kazanan hücre sayılmakta ve yakınlarındaki komşu hücrelerin de ağırlıklarının değiştirilmesine izin verilmektedir (Öztemel, 2012).

4.11 Yapay Sinir Ağlarının Eğitilmesi Ve Test Edilmesi

Yapay sinir ağlarındaki proses elemanlarının (nöronlar) bağlantılarının ağırlık değerlerinin belirlenmesi işlemine ağı eğitilmesi denir. Başlangıçta rasgele atanan bu ağırlık değerleri, ağa örnekler gösterildikçe ağ tarafından değiştirilir. Yapay sinir ağına örnekler defalarca gösterilerek, doğru çıktıları üretecek ağırlık değerlerinin bulunması sağlanır (Öztemel, 2012). İleri beslemeli bir YSA, giriş değerlerini çıkış değerlerine nasıl çevirdiğini açık bir şekilde göstermez, bu ilişkiyi içinde bulunan ağırlık faktörleriyle tanımlar. Ağırlık faktörleri, hata terimi kullanılarak bir parametre optimizasyon tekniği yardımıyla ayarlanmaktadır (Haykin, 1999). Bu tez çalışmasında YSA'larının eğitiminde, Levenberg - Marquardt algoritması kullanılmıştır. Quasi - Newtoniyen metotlardan olan Levenberg - Marquardt algoritması, modelleme kısmında detaylıca anlatılacaktır.

5. YSA İLE DOĞAL GAZ TÜKETİM TAHMİNİ

Çalışmada, yapay sinir ağları kullanılarak Konya iline ait günlük doğal gaz tüketim tahmini yapılmıştır. Doğal gaz tüketimine etki eden parametreler, doğal gaz kullanan abone sayısı yerine kullanılacak olan bbs verisi, meteorolojik parametreler, bu parametrelerden türetilmiş diğer önemli parametreler olarak detaylıca incelenmiş ve tüketim üzerindeki etkileri gösterilmiştir.

5.1 Konya Bölgesi İçin Doğal Gaz Tüketim Öngörüsü

Bu çalışmada kullanılan veri seti Enerya Konya Gaz Dağıtım A.Ş.'den temin edilmiş olup, 2005-2015 yılları arasındaki Sm^3 cinsinden günlük doğal gaz tüketim miktarlarından oluşmaktadır. Dağıtım şirketinden alınan geçmiş tüketim verileri, abone ve Kademe-1 serbest tüketicilerine ait toplam tüketimlerdir. Burada doğal gaz piyasasındaki “Kademe” kavramından bahsetmekte fayda vardır.

Doğal gaz piyasasında, kullanıcı profilleri yıllık toplam tüketim miktarına göre gruplandırılmıştır. Mevzuata göre serbest tüketiciler ve serbest olmayan tüketiciler (abone) olmak üzere iki ana grup vardır. Doğal Gaz Piyasası Lisans Yönetmeliği'ne (07 Eylül 2002 tarihli ve 24869 sayılı Resmi Gazete) göre serbest tüketici ve serbest olmayan tüketici (abone) kavramları açıklanmıştır.


Serbest tüketici, yurt içinde herhangi bir üretim şirketi, ithalat şirketi, dağıtım şirketi veya toptan satış şirketi ile doğal gaz alım-satım sözleşmesi yapma serbestisine sahip gerçek veya tüzel kişiyi ifade ederken; serbest olmayan tüketici (abone), doğal gazı kendi kullanımı için dağıtım şirketlerinden almak zorunda olan gerçek veya tüzel kişiyi ifade eder.

Dağıtım şirketlerinden gaz tedarik eden serbest tüketici grubu iki kademeye göre ayrılmıştır. Kademe-1, yıllık gaz çekiş miktarı 300.000 Sm^3 ve altında olan tüketiciler için kullanılırken; Kademe-2, yıllık gaz çekiş miktarı 300.001 Sm^3 ve üzerinde olan tüketici grupları için kullanılmaktadır. BOTAŞ doğal gaz toptan satış tarifelerine göre, serbest olmayan tüketici (abone) ile Kademe-1 serbest tüketicileri aynı satış

tarifesinden faydalanmaktadır (Url-2). Yıllık doğal gaz tüketimi daha yüksek olan Kademe-2 tüketici grubu için uygulanan satış tarifesini ise daha düşüktür (Url-2).

Dağıtım şirketinden alınan geçmiş tüketim verileri, abone (hanehalkı) ve Kademe-1 serbest tüketicilerine ait toplam tüketimlerdir. Çalışmaya büyük sanayi müşterileri dâhil edilmemiştir. Kademe-1 serbest tüketicileri, küçük ölçekli işletmeler, ticarethane, resmi daireler, okullar, hastaneler, alışveriş merkezleri vs. olarak düşünülebilir. Abone ise ısınma amaçlı doğal gaz kullanan hanehalkını ifade eder. Her iki grubun da doğal gaz kullanımını öncelikli olarak ısınma, daha sonra sıcak su ve mutfaklarda pişirme amaçlıdır.

Şekil 5.1’de 2005-2015 yılları arasındaki günlük doğal gaz tüketimleri gösterilmiştir. Konya bölgesine ait tüketimler, doğal gaz kullanan abone sayısı arttıkça hızla yükselişe geçmiş ve kış aylarında artan, yaz aylarında azalan bir profile sahip olmuştur.




Şekil 5.1: Konya ili 2005-2015 yılları arası doğal gaz tüketimi.

Bazı yıllarda gözlenen pik tüketimler, çok soğuk geçen kış aylarında gözlemlenmiştir. Buna karşılık, yaz dönemlerinde sadece pişirme ve sıcak su ihtiyacı için kullanılan doğal gaz tüketim miktarları neredeyse sabit kalmış ve minimum değerlere ulaşmıştır. Sıcaklıkla ve mevsimlerle doğrudan ilişkili olan doğal gaz tüketiminin abone sayısı ve sıcaklıkla nasıl değiştiği ilerleyen bölümlerde detaylı olarak incelenecektir.

5.2 Doğal Gaz Tüketimine Etki Eden Parametreler

5.2.1 Abone sayısı (BBS)

Doğal gaz hizmet alımı yapacak abonelerin abone bağlantı bedeli hesaplanırken doğal gazın kullanılacağı alanın büyüklüğüne göre hesaplama yapılır. Bu hesaplamada ölçüt olarak bağımsız bölüm sayısı (BBS) kullanılır. Bağımsız bölüm, inşası tamamlanmış, kullanılır durumda olan yapının ayrılmış bölümleridir. Bağımsız bölüm sayısı (BBS); dairenin 200 m²'ye kadar alanı için 1 BBS, 200 m²'den sonra ilave her 100 m² için ilave 1 BBS eklenerek hesaplanır. Çalışmada, abone sayısının yerine BBS kullanılmıştır. Şekil 5.2'de dağıtım şirketine ait tüketimlerin, ilerleyen yıllarda abone sayısı arttıkça nasıl değiştiği görülmektedir. BBS arttıkça, abonelerin kullandığı gaz miktarı da artmaktadır.



Şekil 5.2: Abone sayısı ile tüketimin değişimi.

Dağıtım şirketinden temin edilen geçmiş yıllara ait tüketim verisinin abone sayısı ile nasıl değiştiğini incelemek ve model veri setinde kullanmak üzere, her iki abone grubu için de BBS değerleri dağıtım şirketinden tedarik edilmiştir. Kullanılan BBS verisi, doğal gaz hizmeti almak üzere yapılan abone sözleşmelerinden, sözleşmesi feshedilen abonelere ait BBS verileri çıkarılarak elde edilen aktif abone BBS'leridir. Günlük

olarak alınan BBS ile aynı güne karşılık gelen doğal gaz tüketimleri karşılaştırıldığında doğrusal bir ilişki görülmektedir.

Başta sıcaklık olmak üzere hava şartları, konutlardaki doğal gaz tüketimini etkileyen en önemli faktör olsa da ileriye dönük bir tüketim tahmini yapılacaksa abone sayısının değişimi de modelin içine dâhil edilmesi gereken bir parametredir.

5.2.2 Meteorolojik parametreler

Günlük doğal gaz tüketimini etkileyen en önemli parametre sıcaklık olup, nem, yağış miktarı, rüzgar hızı, güneşlenme süresi gibi diğer meteorolojik veriler de tüketim miktarının değişmesinde etkili olabilmektedir.

Çalışmada kullanılan tüm meteorolojik veriler, Meteoroloji Genel Müdürlüğü'ne (MGM) ait, Türkiye Meteorolojik Veri Arşiv Sistemi (TÜMAS) üzerinden temin edilmiştir (Url-6). Otomatik ölçüm istasyonlarında kaydedilen ve insansız olarak yapılan otomatik hava ölçüm değerleri (klima rasatlarından alınan), sipariş yoluyla MGM'den alındıktan sonra, interpolasyon yöntemiyle eksik veriler tamamlanmıştır.


MGM'den alınan veriler, 37°52'7.32" K enlemi, 32°28'16.68" D boylamı üzerinde yer alan Konya istasyonuna aittir. Günlük ortalama sıcaklık (°C), günlük minimum sıcaklık (°C), günlük maksimum sıcaklık (°C), günlük ortalama nem (%), günlük ortalama rüzgar hızı (m/s) ve günlük toplam yağış miktarı (mm) MGM'den edinilen ve çalışmada kullanılan meteorolojik verilerdir.

5.2.2.1 Sıcaklık

Doğal gaz, hanehalkı tarafından öncelikli olarak ısınma, daha sonra sıcak su ve mutfaklarda pişirme amaçlı kullanılmaktadır. Hanehalkının ve diğer tüketici gruplarının ısınma amaçlı kullandığı doğal gaz miktarı kış aylarında artmakta, yaz aylarında ise azalarak neredeyse sabit kalmaktadır. Özellikle kış aylarında tüketim üzerindeki en önemli etkiye sahip olan dış ortam sıcaklığı, çalışmada detaylıca ele alınmıştır.

Şekil 5.3'te Konya istasyonundan alınan günlük minimum-ortalama-maksimum sıcaklık değerlerinin yıl içinde ve yıllar arası nasıl değiştiği gösterilmektedir. Farklı

yıllardaki sıcaklık değerleri değişse de sıcaklığın mevsimsel salınımı aynı kalmakta ve kış aylarında azalıp yaz aylarında artmaktadır.




Şekil 5.3: Günlük sıcaklık değerlerinin zamanla değişimi.

MGM’den temin edilen ve interpolasyon yöntemiyle eksikleri tamamlanan sıcaklık değerlerine ait özellikler aşağıdaki gibidir:

- Günlük ortalama sıcaklık ($^{\circ}\text{C}$), gün öncesi saat 21:00 ile gün içi saat 07:00, 14:00 ve 21:00 saatlerinde kaydedilen dört farklı sıcaklık değerinin ortalamasıdır.
- Günlük minimum sıcaklık ($^{\circ}\text{C}$), gün öncesi saat 21:00 ile gün içi saat 21:00 saatleri arasında ölçülen minimum değerdir.
- Günlük maksimum sıcaklık ($^{\circ}\text{C}$), gün öncesi saat 21:00 ile gün içi saat 21:00 saatleri arasında ölçülen maksimum değerdir.

Bu sıcaklık parametrelerinin yanında, tüketim üzerindeki etkilerini araştırmak üzere gün öncesi ortalama sıcaklık ($^{\circ}\text{C}$), gün öncesi maksimum sıcaklık ($^{\circ}\text{C}$), gün öncesi minimum sıcaklık ($^{\circ}\text{C}$), gün öncesi ortalama sıcaklık farkı ($^{\circ}\text{C}$), gün öncesi minimum sıcaklık farkı ($^{\circ}\text{C}$), gün öncesi maksimum sıcaklık farkı ($^{\circ}\text{C}$) gibi sıcaklık parametreleri de modelleme kısmında girdi olarak kullanılmıştır.


Şekil 5.4'te, doğal gaz tüketimi ile sıcaklık arasındaki ters ilişkiyi açıkça gösterilmektedir. Sıcaklık, tüketim üzerinde doğrudan etkili olmaktadır. Sıcaklığın düştüğü dönemlerde tüketim hızla artarak yıl içinde en yüksek değerlere ulaşırken; sıcaklığın arttığı yaz dönemlerinde ise azalarak en düşük seviyelere inmektedir.



Şekil 5.4: Günlük doğal gaz tüketiminin sıcaklık ile değişimi.

5.2.2.2 Nem


Nem, havadaki su buharı miktarıdır. Hava sıcaklığının yüksek olduğu günlere nazaran, düşük olduğu günlerdeki nem oranı genellikle daha fazladır. Havadaki nem oranı bölgelere göre değişiklik göstermektedir. Konya bölgesindeki günlük ortalama nem yüzdesi ve nem ile doğal gaz tüketiminin nasıl değiştiği Şekil 5.5'te gösterilmiştir. Şekilden de anlaşılabacağı üzere, sıcaklığın aksine, nem ile doğal gaz tüketimi arasında doğru orantı bulunmaktadır. Havadaki nem oranının yüksek olduğu günlerde tüketim miktarı yüksekken, havadaki nem oranının düşük olduğu sıcak dönemlerde ise tüketim miktarı da düşük olmaktadır. Havadaki nem oranı, insanların hissettiği sıcaklığı doğrudan etkilemektedir. Nem oranının yüksek olduğu kış günlerinde hissedilen sıcaklık daha da düşük olmaktadır. Nem, tüketime etki eden en önemli parametrelerden biri olup, model sonuçlarına olan etkisi ileriki bölümlerde gösterilmiştir.



Şekil 5.5: Günlük doğal gaz tüketiminin nem ile değişimi.

5.2.2.3 Yağış miktarı

MGM’den temin edilen günlük toplam yağış miktarı verisi, gün öncesi 06:00 UTC (Koordine edilmiş evrensel saat) saatten gün içi 06:00 UTC saate kadar ölçülen toplam yağış miktarıdır ve Şekil 5.6’da doğal gaz tüketimi ile beraber gösterilmektedir.




Şekil 5.6: Günlük doğal gaz tüketiminin yağış miktarı ile değişimi.

Konya bölgesindeki geçmiş yıllara ait yağış miktarları (mm) ve bu yağışların doğal gaz tüketimine etkisi incelendiğinde, günlük yağış miktarının, sıcaklık ve neme göre tüketim üzerinde belirgin bir etkisinin bulunmadığı anlaşılmaktadır. Fakat sıcaklık, nem, rüzgar hızı gibi diğer meteorolojik parametrelerle beraber kullanıldığında nasıl sonuç verdiğini incelemek üzere farklı YSA yapılarında girdi olarak kullanılmıştır.

5.2.2.4 Rüzgâr hızı

Çalışmada kullanılan ve MGM'den temin edilen günlük ortalama rüzgar hızı (m/s), 00:00-23:59 saatleri arasında klima rasatlarında kaydedilen rüzgar hızlarının ortalamasıdır. Şekil 5.7'de de görüleceği üzere, rüzgar hızının doğal gaz tüketimine etkisi yok denecek kadar azdır. Fakat ilerleyen bölümlerde, diğer meteorolojik parametrelerle kullanıldığında etkisinin nasıl değiştiğini gözlemlemek üzere çalışmalara dâhil edilmiştir.



Şekil 5.7: Günlük doğal gaz tüketiminin rüzgar hızı ile değişimi.


5.2.3 Türetilmiş parametreler

Tüketime etkisi olan meteorolojik parametreler yukarıdaki bölümde ele alınmıştır. Bu bölümde ise birden fazla parametrenin bir araya gelmesiyle ya da parametrelerin türetilmesiyle elde edilen farklı sıcaklık parametreleri incelenecektir.

5.2.3.1 Derece-gün (HDD)

Derece-Gün, baz bir sıcaklık ile 24 saatlik ortalaması alınan dış ortam sıcaklığının arasındaki farktır. Isıtma Derece-Günleri, 24 saatlik periyodun ne kadarının soğuk geçtiğini ölçmeye yarayan bir birimdir (EİE, 1991). Farklı bölgelerdeki farklı iklim koşulları ısıtma veya soğutma enerjisi ihtiyacını önemli ölçüde etkilemektedir. Bu nedenle, farklı coğrafi bölgeler için farklı Isıtma Derece-Gün (Heating Degree Days - HDD) değerleri belirlenmektedir. Türkiye için de farklı çalışmalar yapılmış, farklı baz sıcaklık değerleriyle uzun dönem sıcaklık verileri kullanılarak derece gün değerleri hesaplanmış ve Türkiye farklı ısıtma derece-gün bölgelerine ayrılmıştır (Sensoy ve diğerleri, 2007; Bulut ve diğerleri, 2007; Satman, 1999).

Türkiye için yapılan çalışmalarda baz (eşik) sıcaklık genellikle 18°C olarak esas alınmıştır. Bu baz sıcaklığın Konya için uygunluğunu tespit etmek için doğal gaz tüketim miktarının günlük ortalama sıcaklığa göre nasıl değiştiği incelenmiştir. Şekil 5.8’de de görüldüğü üzere, tüketim miktarı belli bir eşik sıcaklığa kadar artıp azalmakta fakat eşik sıcaklıktan yüksek dış ortam sıcaklıklarında ise tüketim miktarı neredeyse sabit kalmaktadır. Bu durumda Konya için yapılacak ısıtma derece-gün hesabında baz sıcaklığı 18 °C olarak almak uygun olmaktadır.



Şekil 5.8: Doğal gaz tüketiminin sabit kaldığı baz sıcaklığın bulunması.


Çalışmalarda girdi değeri olarak kullanılacak olan HDD hesabı aşağıdaki gibi yapılmaktadır:

$$HDD = 18^{\circ}C - T_{ort} \quad (5.1)$$

T_{ort} = Günlük ortalama sıcaklık ($^{\circ}C$)

Eğer $T_{ort} > 18^{\circ}C$ (ısıtma eşiği) ise $HDD = 0$ dır.

Şekil 5.9'da doğal gaz tüketimi ile derece gün arasındaki ilişki gösterilmektedir. Derece-gün değerlerinin sıfır olduğu zamanlarda gözlenen yılın en düşük tüketim değerleri, ısınma amaçlı olmayıp doğal gazın farklı alanlarda kullanıldığına işaret etmektedir.



Şekil 5.9: Doğal gaz tüketimi ile derece gün arasındaki ilişki.

Tüketim üzerinde doğrudan etkisi olan derece-gün parametresi, farklı YSA modellerinde girdi olarak kullanılmış ve sonuçlar ilerleyen bölümlerde açıklanmıştır.

5.2.3.2 Hissedilen sıcaklık


Hissedilen Sıcaklık, termometrenin ölçtüğü fiziksek hava sıcaklığından farklı olarak, insan vücudunun hissettiği, algıladığı sıcaklıktır. Bu sıcaklık değeri termometre sıcaklığı, nem, rüzgâr ve radyasyon gibi dört meteorolojik faktörden etkilendiği gibi, iklimsel çevre, giysilerin ısı direnci, vücut yapısı ve kişisel durumdan da etkilenebilmektedir (Url-6). Çalışmada kullanılan hissedilen sıcaklık parametresinde dış ortam sıcaklığı ve nem arasındaki ilişkiyi gösteren ısı indeksi ele alınmıştır. Isı

indeksi ve wind-chill, hissedilen sıcaklığı açıklayan ve en çok bilinen indeks değerlerindendir. Ulusal Hava Servisi-Hava Tahmin Merkezi (National Weather Service (NWC)-Weather Prediction Center) tarafından yapılan araştırmalara göre sıcaklık ve nem arasındaki ilişkiyi gösteren ısı indeksi (heat index) eşitliği aşağıdaki gibi gösterilmiştir. Isı indeksi, R.G. Steadman tarafından 1979'da Applied Meteorology Journal'da yayınlanan bir makalede sıcaklık ve nem dışında bir dizi faktör ele alınarak geliştirilmiştir (Steadman,1979). NWC tarafından çıkarılmış olan, Steadman'ın çalışmasındaki sonuçlara uygun değerleri veren formül aşağıda gösterilmiştir (Url-7):

$$Isı\ Indeksi\ (^{\circ}F) = 0,5 \times \{T + 61 + [(T - 68) \times 1,2] + (rH \times 0,094)\} \quad (5.2)$$


$$T = Dış\ ortam\ sıcaklığı\ (^{\circ}F); \quad rH = Bağıl\ nem\ (\%) \quad (5.3)$$

Bulunan ısı indeksi değerleri $^{\circ}C$ 'a çevrilerek, çalışmada hissedilen sıcaklık parametresi olarak kullanılmıştır. Şekil 5.10'da görüleceği gibi, hissedilen sıcaklık değerlerine ait dağılım dış ortam sıcaklığına paralel değişmektedir.



Şekil 5.10: Sıcaklık, nem ve hissedilen sıcaklık arasındaki ilişki.

Nem oranının yüksek olduğu kış dönemlerinde hissedilen sıcaklığın daha düşük olduğu ve buna bağlı olarak tüketim miktarının daha yüksek olduğu Şekil 5.11'de de görülmektedir.



Şekil 5.11: Doğal gaz tüketimi ile hissedilen sıcaklık arasındaki ilişki.

İlerleyen bölümlerde, sıcaklık ve nemin iki ayrı girdi olarak kullanıldığı YSA modelleri ile hissedilen sıcaklığın tek girdi olarak kullanıldığı YSA modelleri karşılaştırılacak ve tüketim üzerindeki etkisi günlük ortalama sıcaklıktan çok farklı olmayan bu parametrenin sonuçlara etkisi incelenecektir.

5.2.3.3 Rüzgâr etkisi (wind chill)

Wind chill, hava hareketinin (rüzgârın) cilt üzerine yaptığı zorlanmış taşınımın bir ölçüsüdür fakat gerçek bir soğukluk ölçüsü değildir (Url-6). Tek başına rüzgâr hızı tüketim değerleri üzerinde etkili olmazken, sıcaklıkla beraber ele alındığında nasıl bir etki yapacağını gözlemlemek için wind chill değerleri hesaplanmıştır. Hesaplamalarda kullanılan formül Ulusal Hava Servisi (National Weather Service)'nden alınmıştır (Url-8).

$$Wind\ Chill\ (^{\circ}F) = 35,74 + 0,6215 \times T - 35,75 \times v^{0,16} + 0,4275 \times T \times v^{0,16} \quad (5.4)$$


$$T = Dış\ ortam\ sıcaklığı\ (^{\circ}F)$$

$$V = Rüzgar\ hızı\ (m/s)$$

Wind-chill hesabında kullanılan ortalama sıcaklık değerleri $^{\circ}F$ 'ye çevrilmiştir. Bulunan wind-chill değerleri çalışmada girdi olarak kullanılmak üzere tekrar $^{\circ}C$ 'a dönüştürülmüştür:

$$Wind\ Chill\ (^{\circ}C) = (Wind\ Chill\ (^{\circ}F) - 32)/1,8 \quad (5.5)$$

Sıcaklığın farklı bir göstergesi olan wind-chill sıcaklığı, Şekil 5.12’de gösterildiği gibi ortalama sıcaklık değerleri ile aynı etkiyi göstermiştir. Bunun nedeni, ısınma amaçlı doğal gaz kullanan hanehalkının kapalı ortamdayken rüzgârın etkisini hissetmemesidir. Rüzgârın zayıf etkisinden dolayı, bundan sonraki çalışmalarda wind-chill yerine ortalama sıcaklık verilerinin kullanılması uygun bulunmuştur.




Şekil 5.12: Sıcaklık, rüzgar hızı ve wind-chill arasındaki ilişki.

5.2.4 Diğer parametreler

Doğal gaz genellikle ısıtma amaçlı kullanıldığından, hava sıcaklığı ve diğer meteorolojik parametreler tüketim miktarları üzerinde daha etkili olmaktadır. Bir önceki bölümde ele alınan parametrelere ait geçmiş veriler bulunabildiği için analiz edilebilmiştir. Fakat, günlük toplam güneşlenme süresi, havadaki bulutluluk oranı, yağış türü, kullanıcı profili, kullanılan ısıtıcı vb. araçlar, binaların yalıtımı, kullanıcıların ekonomik durumları gibi birçok faktör günlük doğal gaz tüketimine etki etse de bu faktörlere ait sağlam ve işe yarar veri elde edilemediğinden çalışmada bu faktörlere yer verilmemiştir. Keza, bu faktörlere ait eksik ya da sağlıklı verilerin kullanılması da tüketim öngörüsünün başarımını azaltabilir. Meteorolojik verilerin dışında, tüketime etki eden diğer parametrelerden olan doğal gaz satış fiyatı ve tatil günleri aşağıdaki bölümlerde incelenmiştir.

5.2.4.1 Doğal gaz satış fiyatı

BOTAŞ'ın dağıtım şirketleri için uyguladığı doğal gaz toptan satış tarifeleri ve satış fiyatları yılın farklı zamanlarında değişip, azalıp artabilmektedir. Satış fiyatlarındaki bu değişimlerin kullanıcıların doğal gaz tüketim miktarlarını nasıl etkilediği Şekil 5.13'te gösterilmektedir.



Şekil 5.13: Doğal gaz satış fiyatının kullanıcı tüketimlerine etkisi.


Abone sayısı ve zaman içinde artış gösteren tüketim miktarı ve bbs başına düşen tüketim miktarları şekilde gösterilmiştir. Dağıtım şirketinin kurulduğu ilk yıllardaki abone artış hızı diğer yıllara göre daha fazla olmuş, 2010 yılından sonra ise bbs başına tüketim aynı seviyelerde seyretmiştir. Açıkça görülmektedir ki, doğal gaz fiyatının çok yükseldiği zamanlarda bile kullanıcıların doğal gaz tüketim miktarlarında dikkate değer bir değişim olmamıştır. Bu nedenle çalışmada doğal gaz satış fiyatı giriş parametresi olarak kullanılmamıştır.

5.3 Çalışmada Kullanılan YSA Yapısı Ve Mimarisi

Yapay sinir hücreleri (nöronlar), en temel haliyle; girdiler, ağırlıklar, toplama fonksiyonu, aktivasyon fonksiyonu ve çıkış olmak üzere beş bileşenden oluşur. Girdiler, hücreye dış dünyadan gelen bilgiler olup, veri üzerinde hiçbir matematiksel

işlem yapmadan sadece iletili görevini yerine getirerek verileri bir sonraki aşamaya iletir. Ağırlıklar, hücreye gelen bilginin önemini ve hücre üzerindeki etkisini gösterir. Ağırlıkların değiştirilmesiyle ağlardaki öğrenme işlemi sağlanır. Toplama fonksiyonu, girdi değerlerinin ağırlıklarıyla çarpılarak toplanmasını ve ağa gelen net girdinin bulunmasını sağlar. Toplama fonksiyonundan gelen net girdiyi işleyerek, hücre tarafından bu girdiye karşılık olarak üretilecek çıktının belirlenmesini sağlayan ise aktivasyon fonksiyonudur. Bu çalışmada, Logaritmik Sigmoid ve Pure-linear aktivasyon fonksiyonları kullanılmıştır. Çıkış değeri ise, girdiler kullanılmak suretiyle aktivasyon fonksiyonu tarafından belirlenerek dış dünyaya veya başka bir hücreye gönderilmek üzere hazır hale getirilir.

Yukarıda belirtildiği şekilde birden fazla yapay sinir hücresi bir araya gelerek yapay sinir ağlarını oluşturmaktadır. Bu çalışmada kullanılan yapay sinir ağlarının yapısal özellikleri ve mimarisi ilerleyen bölümlerde detaylı olarak açıklanacaktır. Kullanılan yapay sinir ağlarına ait genel yapı ve mimarinin anlaşılması için Şekil 5.14 örnek olarak verilebilir.



Şekil 5.14: Tez çalışmasında kullanılan genel YSA yapısı.

Yapay sinir ağını oluşturan hücreler üç tabaka halinde ve her tabaka içinde birbirine paralel olarak bir araya gelerek yapay sinir ağını oluşturur. Şekil 5.14'te görüldüğü gibi, giriş tabakası en az bir girdi elemanın bulunduğu bölümdür ve bu bölümde genellikle bilgi işleme olmaz. Doğal gaz tüketim tahmini yapılırken, tüketimi etkileyen tüm parametreler giriş tabakasında girdi elemanı (nod) olarak yerini alır. Çalışmada kullanılan giriş parametreleri ilerleyen bölümlerde açıklanmaktadır.

Giriş tabakasından gelen bilgilerin işlenerek çıkış tabakasına gönderildiği kısım ise gizli tabakadır. YSA'lar her ne kadar birden çok gizli tabaka içerebilirlerse de, teorik

olarak ispatlanmıştır ki yeterince nörona sahip tek gizli tabaka birden çok gizli tabakanın yaptığı işi yapabilir (Barutçu, 2013). Keza bu çalışmada da tek gizli tabakadan oluşan yapay sinir ağı kullanılmıştır.

Çıkış tabakası ise gizli tabakadan gelen bilgileri işleyerek giriş tabakasında sunulan girdi seti için gerekli çıktıyı üreten son tabakadır.

Çalışmada kullanılan yapay sinir ağı modelleri Şekil 5.14'te olduğu gibi ileri beslemeli mimariye sahiptir. İleri beslemeli ağlarda, nöronlar yalnızca bir sonraki tabakada bulunan nöronlarla bağlantıya sahiptir. İşaretler sadece tek yönlü olup giriş tabakasından çıkış tabakasına doğrudur. Aynı tabaka içindeki nöronların birbirleriyle bağlantısı olmaz ve ağıın çıktısı, tamamen ağa giren giriş parametrelerine bağlıdır.

5.4 Yapay Sinir Ağlarının Eğitilmesi ve Test Edilmesi

Yapay sinir ağlarındaki proses elemanlarının (nöronlar) bağlantılarının ağırlık değerlerinin belirlenmesi işlemine ağıın eğitilmesi denir. Başlangıçta rastgele küçük sayılar olarak atanan bu ağırlık değerleri, ağa örnekler gösterildikçe ağ tarafından değiştirilir. İleri beslemeli bir YSA, giriş değerlerini çıkış değerlerine nasıl çevirdiğini açık bir şekilde göstermez ancak, bu ilişkiyi içinde bulunan ağırlık faktörleriyle tanımlar. Yapay sinir ağına, örnekler birçok defa gösterilerek, doğru çıktıları üretecek ağırlık değerlerinin bulunması sağlanır.

Bu çalışma kapsamında, 2005-2015 yıllarına ait 11 senelik giriş-çıkış verisinin 10 senelik kısmı (2005-2014) ağların eğitilmesi için kullanılırken, 1 senelik veri seti (2015) test için kullanılmıştır. Eğitimde kullanılan veri sayısının yüksek olması, ağıın daha fazla örnekleme yaparak girdi ve çıktı değerleri arasında daha iyi ilişki kurulmasına olanak sağlamaktadır.

İleri beslemeli YSA'larının eğitiminde, Levenberg – Marquardt (LM) algoritması kullanılmıştır. Levenberg-Marquardt (LM) algoritması, yapay sinir ağlarının eğitiminde sağlamış olduğu hız ve kararlılık nedeni ile genellikle tercih edilmektedir. LM algoritması ve bu algoritma ile eğitim işleminin nasıl gerçekleştiği ilerleyen bölümde detaylıca anlatılmaktadır.

5.4.1 Levenberg-Marquardt metodu ile ileri-beslemeli YSA eğitimi

İleri-Beslemeli bir YSA $x(x_1, \dots, x_n)$ seklindeki bir giriş işareti serisini bir ya da daha fazla çıkış işaretine $y(y_1, \dots, y_m)$ çevirir. Bu durum denklem 5.6 ile ifade edilebilir.

$$y_j = f_j(x) \quad j = 1, \dots, m \quad (5.6)$$

Bununla birlikte, bir YSA bu ilişkiyi açık bir şekilde göstermez ancak, içinde bulunan ağırlık faktörleriyle tanımlar. Bir j nöronunun net girişi hesaplanırken, evvelki tabakada bulunan tüm m nöronlarından gelen çıkışlar değerlendirilmektedir. Giriş işareti kümesinin değerleri genellikle $-1 / +1$ aralığına normalize edilir. j . nöronun net değeri Net_j , denklem 5.7’de gösterildiği gibi hesaplanmaktadır.

$$Net_j = \sum_{i=1}^n w_{ji} x_i \quad (5.7)$$

Burada w_{ji} terimi, i . ve j . nöronlar arasındaki ağırlık değerlerini ifade etmektedir. j . nöronun çıktısı y_j denklem 5.8’de görüldüğü gibi ifade edilebilir.

$$y_j = f(Net_j) = 1 / [1 + \exp(-\alpha Net_j + \theta_j)] \quad (5.8)$$

f fonksiyonu, aktivasyon fonksiyonu olarak adlandırılır ve burada verilen örnekte bir sigmoid fonksiyonudur. θ_j , j . nöron için eşik değeridir. Eğitim sırasında, y_j çıkışlarını elde etmek için giriş örüntüleri ağı girilir. Bulunan sonuç, hedeflenen çıkış t_j ile kıyaslanır. Bundan sonra, ağı ağırlık faktörleri denklem 5.9’da gösterilen hata terimini minimize etmek için değiştirilir.

$$J(w) = \frac{1}{2} \sum_j (y_j - \hat{y}_j)^2 \quad (5.9)$$

Ağırlık faktörleri, hata terimi kullanılarak bir parametre optimizasyon tekniği yardımıyla ayarlanmaktadır (Haykin, 1999).

5.4.2 Levenberg-Marquardt algoritması

Levenberg - Marquardt methodu, bir lineer denklem takımının çözümü olan bir arama doğrultusu kullanır (Levenberg, 1944; Marquardt, 1963). Levenberg - Marquardt methodu, Gauss - Newton doğrultusu ile en dik yokuşun arasında bir çaprazlama arama yönü kullanmaktadır.

Bütün Quasi - Netwon metotları gibi Levenberg - Marquardt algoritması da, ikinci derece eğitim hızına Hessian Matrisini hesaplamadan yaklaşmak üzere tasarlanmıştır. Başarım fonksiyonu toplamların karesi formuna (ileri-beslemeli YSA'ların eğitilmesinde genelde olduğu gibi) ulaştığı zaman, Hessian Matrisi tahmin edilebilmekte ve gradyan bir Jakobiye Matrisi olarak hesaplanabilmektedir. Jakobiye Matrisi, ağırlıklara ve bias'lara bağlı olan ağ hatalarının birinci dereceden türevlerini içermekte ve $\mathbf{e}$ de ağ hatalarının bir vektörü olmaktadır. Jakobiye Matrisi, standart bir geri - yayılım tekniği ile Hessian Matrisinin hesaplanmasına göre çok daha basit bir şekilde hesaplanabilmektedir. Levenberg - Marquardt Algoritması aşağıdaki gibi özetlenebilir:

Algoritma: Öngörü hatalarının toplamı olan bir $J(w)$ fonksiyonu verildiğinde

$$J(w) = \frac{1}{2} \sum_{k=1}^K [y(k) - \hat{y}(k)]^2 \quad (5.10)$$

Minimize edici parametreler

$$\hat{w} = \arg \min_{\theta} J(w) \quad (5.11)$$

aşağıdaki algoritma kullanılarak hesaplanabilir:

1. Başlangıç koşullarını ata:

İterasyon indeksini $l=1$ 'e ayarla.

$\hat{w}(1)$ ve $\mu(1)$ 'e başlangıç değerlerini ata ve η 'yı belirle

2. Modeli ve rezidüleri tayin et:

Tüm k örüntüleri ve p parametreleri için $\hat{y}(k)$ ve $\frac{\partial \hat{y}(k)}{\partial w_p}$ 'yi tayin et. Rezidüel

vektör $\mathbf{R}$ 'yi hesapla:

$$r_k = \hat{y}(k) - y(k) \quad (5.12)$$

ve $J(\hat{w}(l))$ 'yi hesapla:

$$J(\hat{w}(l)) = \frac{1}{2} \mathbf{R}^T \mathbf{R} \quad (5.13)$$

Jakobiyen Matrisi $\mathbf{G}$ 'yi hesapla:

$$g_{k,p} = \frac{\partial \hat{y}(k)}{\partial \theta_p} \quad (5.14)$$

3. Parametreleri yenile:

$$\Delta \hat{\mathbf{w}}(l) = -[\mathbf{G}^T \mathbf{G} + \mu(l) \mathbf{I}]^{-1} \mathbf{G}^T \mathbf{R} \quad (5.15)$$

4. $\hat{\mathbf{w}}(l)$ yerine $\hat{\mathbf{w}}(l) + \Delta \hat{\mathbf{w}}(l)$ kullanarak ikinci adımı tekrarla. $J(\hat{\mathbf{w}}(l) + \Delta \hat{\mathbf{w}}(l))$ 'yi hesapla.

Eğer $J(\hat{\mathbf{w}}(l) + \Delta \hat{\mathbf{w}}(l)) < J(\hat{\mathbf{w}}(l))$ ise adım büyüklüğünü artır:

$$\mu(l+1) = \mu(l) / \eta \quad (5.16)$$

ve parametreleri güncelle

$$\hat{\mathbf{w}}(l+1) = \hat{\mathbf{w}}(l) + \Delta \hat{\mathbf{w}}(l) \quad (5.17)$$

değilse adım büyüklüğünü küçült:

$$\mu(l+1) = \eta \mu(l) \quad (5.18)$$

5. $l = l + 1$ olarak ata ve ikinci basamağa dön, ya da çık.

Levenberg-Marquardt Algoritmasının en büyük sorunu, bazı problemlerde çok büyük boyutlara ulaşan birkaç matrisin hafızada saklanması gerektirmesidir.

5.5 Yapay Sinir Ağlarının Test Edilmesi ve Performans Kriterleri

Çalışmadaki model denemelerinin doğruluğunu test etmek için üç ayrı performans kriteri kullanılmıştır. Bunlardan biri yaygın olarak kullanılan R^2 , diğerleri ise rMB ve $rRMS$ 'dir (MESOR, 2009). Ağın başarı performansını test etmek için eğitilmiş ağın öngörmüş olduğu bir senelik tahmini tüketim verileri ile fiili tüketim verileri karşılaştırılmıştır.

R^2 Testi, pek çok çalışmada performans ölçütü olarak kullanılan ve elde edilen tahmin sonuçlarının reel sonuçlarla ilişkisini açıklayan bir testtir. Genel olarak, regresyon kareler toplamının genel kareler toplamına oranı şeklinde ifade edilir (Barutçu, 2013).

$$R^2 = \frac{\text{Regresyon Kareler Toplamı (RKT)}}{\text{Genel Kareler Toplamı (GKT)}} = 1 - \frac{\text{Hata Kareler Toplamı (HKT)}}{\text{Genel Kareler Toplamı (GKT)}}$$

$$R^2 = 1 - \frac{\sum_{i=1}^n (x_e(i) - x_m(i))^2}{\sum_{i=1}^n x_m(i)^2} \quad (5.19)$$

n : veri çifti sayısı

$x_e(i)$ = modellenen veri

$x_m(i)$ = ölçülen veri

R^2 , yukarıdaki eşitlikte de gösterildiği üzere modellenen veri ile ölçülen veri arasındaki farkların kareler toplamının (HKT), ölçülen (reel) verinin kareler toplamına (GKT) bölünüp 1'den çıkarılmasıyla elde edilmektedir. Sonuçların 1'e yakınsaması, modellenen verinin ölçülen veriye ne kadar yaklaştığının bir göstergesidir.

RMS, hata kareleri toplamının veri sayısına bölümünün karekökü olarak ifade edilir. Bağlı ortalama karekök ($rRMS$) ise ortalama karekök hatanın, ölçülen verilerin aritmetik ortalamasına oranı olarak ifade edilir (MESOR, 2009).

$rRMS$ 'nin küçük çıkması, gerçek verilerin ortalamasından çok uzaklaşmadığını ve ortalama karekök hata toplamının küçük olduğunu göstermektedir. Çalışmalarda elde edilen maksimum R^2 ve minimum $rRMS$ değerleri başarı ölçütünün önemli kriterleri olmaktadır.

$$RMS = \sqrt{\frac{1}{n} \sum_{i=1}^n (x_e(i) - x_m(i))^2} ; rRMS = \frac{RMS}{\bar{x}_m} \quad (5.20)$$

$\bar{x}_m$ = ölçülen verilerin aritmetik ortalaması

Bağlı ortalama sapma (rMB) değeri, elde edilen model sonuçlarının gerçek değer ortalamasından ne kadar uzaklaştığının bir göstergesidir. Hata toplamı ortalamasının ölçülen verilerin aritmetik ortalamasına bölünmesiyle elde edilir. rMB pozitif olabileceği gibi negatif de olabilmektedir. Bunun anlamı, gerçek değer ortalamasının ne kadar üstüne çıkıldığı (pozitif) ya da ne kadar altında (negatif) kaldığıdır. rMB 'nin mutlak değeri küçüldükçe gerçek değer ortalamasına yaklaşmaktadır.

$$MB = \frac{1}{n} \sum_{i=1}^n (x_e(i) - x_m(i)) ; rMB = \frac{MB}{\bar{x}_m} \quad (5.21)$$


Çalışmalarda öncelikli olarak kullanılan hata kriterleri R^2 ve $rRMS$ 'dir. rMB ise oluşturulan ağ yapılarının normalden yüksek ya da düşük tahmin yapması hakkında bilgi vermesi açısından önemlidir.

5.6 YSA Uygulaması ve MATLAB (nntool) Kullanımı

Doğal gaz tüketim tahmini yapmak üzere kurgulanan ağ yapıları, MATLAB'in yapay sinir ağı modülünde (neural network tool) çalıştırılmıştır. Ağ yapısına ait bütün özellikler tamamlandıktan sonra birçok deneme yapılarak en iyi performans gösteren ağ yapıları seçilmeye çalışılmıştır.

Daha önceden de açıklandığı gibi, ağ yapıları hazırlanırken girdi değerleri olarak doğal gaz tüketimini etkileyen giriş parametreleri, çıkış değeri olarak ise doğal gaz tüketim miktarı (Sm^3) kullanılmıştır. Oluşturulan ileri beslemeli ağ yapılarında tek gizli tabaka ile çalışılmış ve gizli tabakadaki nöron sayısı değiştirilerek performans değerlerinin nasıl değiştiği incelenmiştir.

Şekil 5.15'te 17 giriş parametresinin kullanıldığı ve 11 nöronlu bir gizli tabaka ve tek çıkıştan oluşan yapay sinir ağının MATLAB'deki gösterimidir.



Şekil 5.15: Örnek bir YSA [17,11,1] yapısının MATLAB gösterimi.

Örnek olarak verilen bu yapıdaki bir sinir ağı, kolaylık olması açısından [17,11,1] şeklinde gösterilecektir. Çalışmadaki tüm ağ yapılarında LM öğrenme algoritması kullanılmış ve her denemede 1000 iterasyon yaptırılarak ağın çıktı değerlerini vermesi sağlanmıştır. Bu işlem her bir ağ denemesi için 10 kez tekrarlanmış ve iyi başarı performansı gösteren ağ sonuçları kaydedilmiştir. Bölüm 5.7 ve devamında, uygulama kısmında yapılan çalışmalar detaylı olarak açıklanacaktır.

5.7 YSA Uygulaması

Çalışmada, doğal gaz tüketimi üzerinde etkisi olan 17 ayrı giriş parametresi kullanılmış olup, bu parametreler 1'den 17'ye kadar numaralandırılarak Çizelge 5.1'de gösterilmektedir. Bu parametrelerin çoğu meteorolojik verilerden temin edilmiş ya da bu verilerden türetilmiştir.

Çizelge 5.1: YSA'larda kullanılan giriş parametreleri.

No	Giriş Parametreleri (GP)
1	Abone Sayısı (bbs)
2	Günlük Ortalama Sıcaklık (°C)
3	Günlük Maksimum Sıcaklık (°C)
4	Günlük Minimum Sıcaklık (°C)
5	Gün Öncesi Ortalama Sıcaklık (°C)
6	Gün Öncesi Maksimum Sıcaklık (°C)
7	Gün Öncesi Minimum Sıcaklık (°C)
8	Gün Öncesi Ortalama Sıcaklık Farkı (°C)
9	Gün Öncesi Maksimum Sıcaklık Farkı (°C)
10	Gün Öncesi Minimum Sıcaklık Farkı (°C)
11	Derece Gün (hdd) (°C)
12	Hissedilen Sıcaklık (°C)
13	Rüzgâr Etkisi (Wind Chill) (°C)
14	Günlük Ortalama Nem (%)
15	Günlük Ortalama Rüzgar Hızı (m/s)
16	Günlük Toplam Yağış Miktarı (mm)
17	Doğal Gaz Satış Fiyatı (TL/Sm ³)

Daha önceki bölümlerde sıcaklıkla doğal gaz tüketiminin doğrudan ilişkili olduğu açıklanmıştı. Hanehalkının doğal gaz tüketim alışkanlıkları düşünüldüğünde, içinde bulunulan hava sıcaklığının yanı sıra önceki güne ait hava sıcaklığının da ısınma ihtiyacı üzerinde etkili olması beklenmektedir. Önceki günlere göre ani sıcaklık değişimlerinin (hızlı ısınma-hızlı soğuma) gerçekleşmesi de kullanılan doğal gaz miktarı üzerinde etkilidir. Bu nedenlerle, gün öncesi sıcaklık değerleri ile gün öncesi sıcaklık farkları da giriş parametresi olarak kullanılmıştır.

Bütün bu parametrelerin doğal gaz tüketimi üzerindeki etkilerini daha iyi yorumlayabilmek için birçok farklı YSA denemesi yapılmıştır. İlk olarak, bütün giriş parametreleri (1-17) kullanılarak ve gizli tabakadaki nöron sayısı (NS) değiştirilerek en iyi YSA modeli elde edilmeye çalışılmıştır.

Ağın mimarisi ve giriş-çıkış parametreleri aynı kalacak şekilde, gizli tabakadaki nöron sayısı 10'dan 40'a kadar arttırılarak performans değerleri R^2 , $rRMS$ ve rMB olarak Çizelge 5.2'deki gibi kaydedilmiştir.


Çizelge 5.2: 17 girişli ağlarda farklı gizli tabaka NS göre başarımların değerleri.

NS	R^2	rMB	$rRMS$
9	0,9924	0,0211	0,1174
10	0,9922	-0,0106	0,1191
11	0,9926	0,0144	0,1158
12	0,9927	-0,0142	0,1152
13	0,9934	0,0033	0,1094
14	0,9936	0,0077	0,1076
15	0,9922	0,0185	0,1194
16	0,9936	-0,0230	0,1083
17	0,9930	-0,0150	0,1131
18	0,9933	-0,0070	0,1107
19	0,9916	0,0313	0,1237
20	0,9922	-0,0044	0,1193
21	0,9922	-0,0123	0,1191
22	0,9915	0,0135	0,1245
23	0,9926	-0,0155	0,1161
24	0,9923	-0,0245	0,1184
25	0,9921	-0,0359	0,1196
26	0,9915	-0,0385	0,1247
27	0,9928	0,0067	0,1144
28	0,9929	0,0029	0,1138
29	0,9924	-0,0104	0,1175
30	0,9922	0,0334	0,1189
31	0,9917	-0,0368	0,1226
32	0,9914	-0,0248	0,1253
33	0,9928	-0,0017	0,1141
34	0,9919	0,0035	0,1211
35	0,9931	-0,0094	0,1124
36	0,9928	0,0248	0,1144
37	0,9927	0,0080	0,1151
38	0,9924	-0,0255	0,1179
39	0,9920	0,0025	0,1205
40	0,9921	0,0019	0,1199

NS: Gizli Tabaka Nöron Sayısı

Söz konusu veriler incelendiğinde, gizli tabakadaki nöron sayısı arttıkça başarı performansının azaldığı gözlemlenmiştir. Şekil 5.16'da, en iyi sonuçları 14 ve 16 nöron sayılı gizli tabakaların kullanıldığı ağların verdiği görülmüştür. Bütün giriş parametreleri kullanıldığında, gizli tabakadaki nöron sayısı 14 olan ağ yapısı 0,9936 ile en yüksek R^2 ve 0,1076 ile en düşük $rRMS$ değerlerini vermiştir. 0,0077 olarak kaydedilen rMB , günlük tahmini tüketim değerleri toplamının, gerçek tüketim


değerlerinin üzerinde çıktığını göstermektedir. 2015 yılına ait toplam tüketim miktarı 359,7 MSm³ (milyon Sm³) olmuşken tahmin sonucu 362,51 MSm³ olarak kaydedilmiştir.



Şekil 5.16: Gizli tabakadaki NS değiştirerek farklı ağ yapılarının denenmesi.

Giriş parametrelerine ait 2015 yılı verileri test için girdi seti olarak kullanılmış ve, bu verilere karşılık ise günlük tahmini doğal gaz tüketim miktarları çıktı olarak elde edilmiştir. Şekil 5.17'de fiili tüketim değerleriyle YSA tahmini tüketim değerleri beraber gösterilmiştir. 365 gün gibi uzun bir zaman dilimi için ağın verdiği çıktılar oldukça başarılıdır. En yüksek tüketimin olduğu kış aylarında bile ağın verdiği günlük tahmin değerlerinin çok sapmadığı görülmektedir.

Fiili tüketim değerleriyle tahmini tüketim değerlerinin karşılaştırıldığı diğer grafikte ise gerçek değerlerden ne kadar sapma olduğu gösterilmektedir. Yaz dönemlerinde neredeyse sabit kalan tüketimin, ağ tarafından da iyi tahminlenmesine rağmen bazı günlerde gerçek değer çok üstünde çıktığı görülmüştür. Bunun nedeni eğitim için kullanılan veri setinde olabilecek anormal sıcaklık değişimleri ya da hatalı veriler olabilir. Diğer göze çarpan nokta ise, mevsim geçişlerinin yaşandığı aylardaki sapma değerlerinin biraz daha yüksek olmasıdır.



Şekil 5.17: Model [17,14,1] sonuçları ile fiili sonuçların karşılaştırılması.


Çalışmanın ikinci kısmında, tüm giriş parametreleri kullanılarak elde edilen en iyi ağ yapısındaki [17,14,1] her bir parametrenin tahmin sonuçları üzerindeki etkisi incelenmiştir. Bir önceki bölümde elde edilen ağ yapısı değiştirilmeden, Çizelge 5.3'te 1'den 17'ye kadar numaralandırılmış giriş parametreleri sırasıyla çıkartılarak yeni modeller denenmiş ve bu modellere ait başarı kriterleri Çizelge 5.3'te verilmiştir. "0" hiçbir parametrenin çıkarılmadığı durumu göstermektedir. Tablodaki sonuçlar, her bir ağın 10 kez koşularak ve 1000 iterasyon yaptırılarak elde edilen sonuçların en iyileridir.

Çizelge 5.3: Giriş parametrelerinin sonuçlara etkisi.


Çıkarılan Parametre	R^2	rMB	$rRMS$
0	0,9936	0,0077	0,1076
1	0,9634	-0,0963	0,2581
2	0,9936	-0,0106	0,1081
3	0,9926	-0,0222	0,1163
4	0,9932	-0,0035	0,1115
5	0,9931	-0,0008	0,1121
6	0,9936	-0,0038	0,1076
7	0,9934	-0,0048	0,1095
8	0,9936	0,0093	0,1076
9	0,9927	0,0039	0,1149
10	0,9938	-0,0030	0,1063
11	0,9936	0,0065	0,1076
12	0,9927	0,0194	0,1154
13	0,9937	0,0021	0,1074
14	0,9929	-0,0242	0,1136
15	0,9926	0,0023	0,1163
16	0,9934	0,0053	0,1094
17	0,9935	-0,0099	0,1086

Bu çalışma çerçevesinde, tüketim üzerinde en yüksek etkiye sahip olan parametreler ile birlikte, kullanılmadığı takdirde sonuçları değiştirmeyen veya daha iyi sonuçların elde edilmesini sağlayan parametreler de ortaya çıkarılmıştır. Daha önceki bölümlerde de açıklandığı üzere, abone sayısının sonuçlar üzerinde büyük ve anlamlı bir etkisi vardır. Abone sayısındaki artış hızı yıllar ilerledikçe azalsa da abone sayısı ve buna bağlı olarak doğal gaz tüketim miktarı artmaya devam etmektedir. Şekil 5.18’de görüleceği gibi, giriş verilerinden bbs verilerinin çıkarıldığı durumda, sonuçların performanslarının fark edilir derecede azaldığı ve R^2 değerinin 0,9936’dan 0,9634’e düşmektedir. Diğer parametrelerin çıkarıldığı durumda R^2 ve $rRMS$ ’deki değişimlerin daha küçük olduğu görülmüştür. 6, 8, 10, 11 ve 13 numaralı giriş parametreleri çıkarıldığında başarı performansı neredeyse değişmemiş ya da sonuçların daha da iyileşmesi sağlanmıştır. Bu sonuçlar göstermektedir ki ağa giriş olarak verilen parametre sayısından ziyade, o parametrenin ne olduğu önem taşımaktadır.

Şekil 5.19 bbs dışındaki parametrelerin sonuçlara etkisini daha iyi göstermek için verilmiştir. Çıkarıldığı takdirde ilk durumdaki başarı performansını (R^2 :0,9936- $rRMS$:0,1076) düşüren giriş parametrelerinin tüketim üzerinde daha etkili olduğu söylenebilir.



Şekil 5.18: Çıkarılan giriş parametrelerinin sonuçlara etkileri.



Şekil 5.19: Çıkarılan giriş parametrelerinin sonuçlara etkileri (bbs dışında).

Gün öncesi maksimum sıcaklık (6), gün öncesi ortalama sıcaklık farkı (8), gün öncesi minimum sıcaklık (10), derece gün (11) ve rüzgâr etkisi-windchill (13)

parametrelerinin kullanılmadığı ağ yapılarında daha iyi sonuçlar gözlenmiştir. Şekil 5.19’da da gösterildiği gibi, 3, 9, 12, 14 ve 15 nolu giriş parametrelerinin tüketim değerleri üzerinde diğerlerine göre daha etkili olduğu görülmüştür.


Çalışmanın bu bölümünde, çıkarıldığı takdirde sonuçlar üzerinde etkisi olmayan, ya da sonuçları iyileştirdiği gözlenen parametrelerin hepsi girişten çıkarılarak sonuçlar kaydedilmiştir. Çizelge 5.4’te bu YSA’ların başarımları gösterilmektedir.

Çizelge 5.4: Değiştirilen gizli tabaka nöron sayılarına göre YSA başarımları.

Çıkarılan Parametre	NS	R^2	rMB	$rRMS$
-	14	0,9936	0,0077	0,1076
6,8,10,11,13	8	0,9934	-0,0128	0,1093
6,8,10,11,13	9	0,9936	-0,0220	0,1076
6,8,10,11,13	10	0,9935	-0,0169	0,1091
6,8,10,11,13	11	0,9936	-0,0005	0,1082
6,8,10,11,13	12	0,9932	0,0242	0,1110
6,8,10,11,13	13	0,9932	-0,0230	0,1111
6,8,10,11,13	14	0,9936	-0,0035	0,1080
6,8,10,11,13	15	0,9940	0,0041	0,1046
6,8,10,11,13	16	0,9934	-0,0071	0,1096
6,8,10,11,13	17	0,9938	-0,0019	0,1065
6,8,10,11,13	18	0,9923	-0,0008	0,1185
6,8,10,11,13	19	0,9935	0,0095	0,1085
6,8,10,11,13	20	0,9930	-0,0177	0,1128

6, 8, 10, 11 ve 13 numaralı parametreler çıkarıldıktan sonra, optimum sonuçları elde etmek üzere gizli tabakadaki nöron sayısı değiştirilerek farklı ağ modelleri denenmiştir. Yapılan denemeler göstermiştir ki, sonuçlar üzerinde etkisi olmadığı düşünülen parametreler girişten çıkarıldığında, referans olarak alınan ağın [17,14,1] başarısına aynı nöron sayısına sahip 12 girişli ağ [12,14,1] yapısıyla da ulaşılmıştır.


Şekil 5.20’de de görüleceği gibi, gizli tabakadaki nöron sayısı değiştirildiğinde ise 15 nöron sayılı yeni ağ [12,15,1] denemesiyle daha yüksek R^2 (0,9940) ve daha düşük $rRMS$ (0,1046) değerleri elde edilmiştir. Ağın 2015 yılı için vermiş olduğu toplam tahmini tüketim 361,2 MSm³ olurken, 359,7 MSm³ olan fiili tüketimin üzerinde gerçekleşmiş ve rMB 0,0041 olarak kaydedilmiştir.



Şekil 5.20: Değiştirilen gizli tabaka nöron sayılarına göre YSA başarımları.

Şekil 5.21’de, gün öncesi maksimum sıcaklık (6), gün öncesi ortalama sıcaklık farkı (8), gün öncesi minimum sıcaklık (10), derece gün (11) ve rüzgar etkisi-windchill (13) parametrelerinin kullanılmadığı ve gizli tabakasındaki nöron sayısı 15 olan YSA çıktılarının fiili tüketim değerleriyle karşılaştırılması verilmiştir.

Ağın, 365 gün gibi uzun bir süre için gerçeğe yakın çıktılar üretebilmesi ve özellikle kış aylarında bu çıktıların fiili değerlerle örtüşmesi, sapma oranlarının düşük olması ağın başarı performansının oldukça yüksek olduğunu göstermektedir. Mayıs, Ekim Kasım gibi mevsim geçişlerinin yaşandığı aylarda günlük sapma değerleri diğer aylara göre daha yüksek olmuştur. Bunun bir nedeni, eğitim için kullanılan 10 yıllık veri setinde benzer mevsim geçişlerinin olması fakat aylık sıcaklık ortalamalarının geçmiş yıllara göre değişebilmesi olabilir. Mevsim geçişleri ve yılın farklı dönemlerinde farklı modellerin kullanılarak yıllık tahmin yapılması bir başka çalışma konusu olarak ayrıca incelenebilir. Çalışmada elde edilen tüm sonuçlar test için kullanılan veri setine (2015 yılı) aittir. Ağa giriş olarak sokulan tüm parametreler 2015 yılı gerçek verileridir. Eğitim sonunda, bu verilere karşılık günlük doğal gaz tüketimi çıktı olarak alınmıştır.



Şekil 5.21: Model [12,15,1] sonuçları ile fiili sonuçların karşılaştırılması.

YSA’larda çıkışın doğruluğunu etkileyen en önemli faktörler ağıın yapısı ve giriş parametrelerinin doğruluğudur. Elde edilen ağ yapısının gerçekleşmemiş bir zamanda kullanılabilmesi ve aynı performansta çıktı üretebilmesi için ağa sunulan giriş değerlerinin de anlamlı olması gerekmektedir. Günümüzde, günlük minimum, maksimum ve ortalama sıcaklık tahmini, günlük ortalama nem ve rüzgar hızı tahmini yapan kuruluşlar mevcuttur. Fakat meteorolojik verilerin uzun dönemli tahmin edilmesi hem zordur hem de tahmin edilen verilerin doğruluğu öngörü ufku uzaklaştıkça azalmaktadır.

Çalışmanın bu kısmında son olarak, tüm sıcaklık parametrelerinin ve erişilebilirliği daha kolay olan giriş parametrelerinin yer aldığı yeni ağ yapıları denenmiştir. Gizli tabakasındaki nöron sayıları değiştirilerek çalıştırılan ağların başarı performansları Çizelge 5.5'teki gibi olmuştur.

Çizelge 5.5: Değiştirilen gizli tabaka nöron sayılarına göre YSA başarımları.


Çıkarılan Parametre	NS	R^2	rMB	$rRMS$
-	14	0,9936	0,0077	0,1076
12,13,15,16,17	8	0,9928	-0,0293	0,1147
12,13,15,16,17	9	0,9937	0,0030	0,1070
12,13,15,16,17	10	0,9934	-0,0213	0,1094
12,13,15,16,17	11	0,9934	0,0222	0,1096
12,13,15,16,17	12	0,9934	-0,0208	0,1098
12,13,15,16,17	13	0,9926	-0,0319	0,1158
12,13,15,16,17	14	0,9936	-0,0092	0,1080
12,13,15,16,17	15	0,9940	-0,0112	0,1049
12,13,15,16,17	16	0,9929	0,0007	0,1134
12,13,15,16,17	17	0,9932	0,0125	0,1111
12,13,15,16,17	18	0,9931	-0,0065	0,1123
12,13,15,16,17	19	0,9920	0,0070	0,1207
12,13,15,16,17	20	0,9926	0,0073	0,1164

Tüketimi etkileyen en önemli faktörler sıcaklık ve sıcaklıktan türetilen parametrelerdir. Hissedilen sıcaklık (12), windchill (13), günlük ortalama rüzgar hızı (15), günlük toplam yağış miktarı (16) ve doğal gaz satış fiyatı (17) gibi parametrelerin doğal gaz tüketimi üzerindeki etkileri daha önceki bölümlerde açıklanmıştı. Rüzgar ve windchill değerleri dışarıda bulunan kullanıcıların hissettiği sıcaklığı etkilerken, kapalı ortamlardaki kullanıcıların tüketim alışkanlıklarını çok değiştirmedeği görülmüştür.

Günlük toplam yağış miktarı ve hissedilen sıcaklık değerleri de sonuçlar üzerinde fark edilir değişikliklere neden olmamıştır. Doğal gaz satış fiyatının doğal gaz tüketim miktarı üzerinde etkili olması beklenirken, sonuçları çok değiştirmedeği gözlemlenmiştir. Bunun nedeni hanehalkının ve diğer kullanıcı gruplarının alternatif yakıt seçeneklerinin olmayışdır.

Şekil 5.22'de bu parametrelerin kullanılmadığı ağ yapıları ile elde edilen sonuçlar gösterilmiştir. Sonuçlara bakıldığında, gizli tabakasinda 15 nöron bulunan ağ yapısının

[12,15,1] yüksek başarı performansı (0,9940; 0,1049) göstererek bir önceki model sonuçlarına (0,9940; 0,1046) ulaştığı gözlenmiştir.




Şekil 5.22: Değiştirilen gizli tabaka nöron sayılarına göre YSA başarımları.

Önceki modellerden farklı olarak, bu ağın vermiş olduğu toplam tahmini tüketim fiili tüketimin altında gerçekleşmiş ve 355,71 MSm³ olmuştur. Bu nedenle rMB negatif ve -0,0112 olarak kaydedilmiştir. Fiili değerlerle ağın çıktısı tahmini değerler Şekil 5.23'te gösterilmiştir.

Tüm sıcaklık parametrelerinin ve erişilebilirliği daha kolay olan giriş parametrelerinin yer aldığı bu ağ yapısında da 365 gün gibi uzun bir süre için gerçeğe yakın tahmini tüketim değerlerine ulaşılabildiği fakat Mayıs, Ekim Kasım gibi mevsim geçişlerinin yaşandığı aylarda günlük sapma değerlerinin diğer aylara göre daha yüksek olduğu görülmüştür.

Yapay sinir ağ modelleriyle elde edilen sonuçların başarı performansını kıyaslamak üzere regresyon analizi yapılmış ve Bölüm 5.8'de detaylandırılmıştır.



Şekil 5.23: Model [12,15,1] sonuçları ile fiili sonuçların karşılaştırılması.

5.8 YSA Model Sonuçlarının Regresyon Model Sonuçlarıyla Karşılaştırılması

Çalışmanın son kısmında, yüksek başarı performansı gösteren [12,15,1] yapay sinir ağ modelinden elde edilen sonuçlar, basit doğrusal regresyon ve çoklu doğrusal regresyon sonuçları ile karşılaştırılmıştır. Tüm sıcaklık parametrelerin ve erişilebilirliği daha kolay olan parametreler kullanılarak oluşturulan basit doğrusal regresyon modelinde R^2 0,779; çoklu doğrusal regresyon modelinde ise R^2 0,967 bulunmuştur. Aynı giriş parametreleriyle elde edilen yapay sinir ağ modelinde ise R^2 değeri 0,9940 olarak bulunmuş ve regresyon modellerine göre daha yüksek başarı performansı göstermiştir.

12 giriş parametresi kullanılarak elde edilen basit doğrusal regresyon denklemi Denklem 5,22’de gösterilmiştir. Burada y , doğal gaz tüketim değerini (Sm^3), x_1 - x_{12} ise tüketime etki eden parametreleri ifade etmektedir. a_0 kesişim noktasını (intercept), a_1 - a_{12} parametrelere karşılık gelen katsayı değerlerini göstermektedir. Bu modele ait R^2 değeri 0,779 olarak bulunmuştur.


$$y = a_0 + a_1x_1 + a_2x_2 + a_3x_3 + a_4x_4 + a_5x_5 + a_6x_6 + a_7x_7 + a_8x_8 + a_9x_9 + a_{10}x_{10} + a_{11}x_{11} + a_{12}x_{12} \quad (5.22)$$

Çizelge 5.6’da, bu modelde kullanılan parametreler ve parametrelere ait regresyon katsayı değerleri gösterilmiştir.

Çizelge 5.6: Basit doğrusal regresyon katsayıları.

Parametre	Tanım	Katsayı	Değer
-		a_0	-3,20E+09
x_1	Abone Sayısı (bbs)	a_1	22.076
x_2	Günlük Ortalama Sıcaklık (°C)	a_2	34855
x_3	Günlük Maksimum Sıcaklık (°C)	a_3	-12170
x_4	Günlük Minimum Sıcaklık (°C)	a_4	91217
x_5	Gün Öncesi Ortalama Sıcaklık (°C)	a_5	0
x_6	Gün Öncesi Maksimum Sıcaklık (°C)	a_6	-9254.2
x_7	Gün Öncesi Minimum Sıcaklık (°C)	a_7	-1,02E+09
x_8	Gün Öncesi Ortalama Sıcaklık Farkı (°C)	a_8	-3087.3
x_9	Gün Öncesi Maksimum Sıcaklık Farkı (°C)	a_9	0
x_{10}	Gün Öncesi Minimum Sıcaklık Farkı (°C)	a_{10}	-88079
x_{11}	Hissedilen Sıcaklık (°C)	a_{11}	58949
x_{12}	Günlük Ortalama Nem (%)	a_{12}	1384.8

Şekil 5.24'te fiili tüketim değerleriyle basit doğrusal regresyon modeline ait tahmini tüketim değerleri karşılaştırılmıştır.



Şekil 5.24: Basit doğrusal regresyon modeli ile fiili sonuçların karşılaştırılması.


Basit doğrusal regresyon modeline alternatif olarak oluşturulan çoklu doğrusal regresyon modeline ait regresyon denklemi Denklem 5,23'te gösterilmiştir. Bu modele ait R^2 değeri ise 0,967 olarak bulunmuştur.

$$\begin{aligned}
 y = & a_0 + a_1x_1 + a_2x_2 + a_3x_3 + a_5x_5 + a_6x_6 + a_7x_7 + a_{10}x_{10} + a_{11}x_{11} + a_{12}x_{12} + \\
 & a_{1-2}x_1x_2 + a_{1-3}x_1x_3 + a_{1-6}x_1x_6 + a_{1-7}x_1x_7 + a_{1-11}x_1x_{11} + a_{1-12}x_1x_{12} + \\
 & a_{2-5}x_2x_5 + a_{2-10}x_2x_{10} + a_{2-12}x_2x_{12} + a_{3-5}x_3x_5 + a_{5-7}x_5x_7 + a_{6-12}x_6x_{12} + \\
 & a_{10-11}x_{10}x_{11} + a_{11-12}x_{11}x_{12}
 \end{aligned} \quad (5.23)$$

Çoklu doğrusal regresyon modeline ait çoklu regresyon katsayı değerleri Çizelge 5.7'de verilmektedir. Basit doğrusal regresyon modelinden farklı olarak, birden fazla parametrenin tüketim üzerindeki etkisini optimize etmek üzere farklı regresyon katsayıları oluşmuştur. Şekil 5.25'te ise fiili tüketim değerleriyle çoklu doğrusal regresyon modeline ait tahmini tüketim değerleri karşılaştırılmıştır.

Çizelge 5.7: Çoklu doğrusal regresyon katsayıları.

Katsayı	Değer
a ₀	4,12E+09
a ₁	-13.702
a ₂	-8372.1
a ₃	-10569
a ₅	1312.3
a ₆	10211
a ₇	2585.2
a ₁₀	35410
a ₁₁	-9417.8
a ₁₂	-6129
a ₁₋₂	0.18848
a ₁₋₃	-0.036444
a ₁₋₆	-0.018678
a ₁₋₇	-0.10033
a ₁₋₁₁	0.35129
a ₁₋₁₂	0.0094776
a ₂₋₅	-1157.1
a ₂₋₁₀	-1491.2
a ₂₋₁₂	431.25
a ₃₋₅	501.21
a ₅₋₇	495.41
a ₆₋₁₂	-211.98
a ₁₀₋₁₁	-1671.9



Şekil 5.25: Çoklu doğrusal regresyon modeli ile fiili sonuçların karşılaştırılması

6. SONUÇ VE TARTIŞMA

Bu çalışmada, yapay sinir ağları kullanılarak Konya iline ait günlük doğal gaz tüketim tahmini yapılmıştır. Yapay sinir ağları, örnekleri kullanarak olayları öğrenebilen ve çevreden gelen olaylara karşı nasıl tepkiler üretebileceğini belirleyebilen bilgisayar programlarıdır. Doğrusal olmayan karmaşık problemleri çözümleyebilme, kendi kendine öğrenebilme, genelleme yapabilme, eğitildikten sonra eksik veriler ile çalışabilme ve yüksek hata toleransına sahip olma gibi üstün özellikler, yapay sinir ağlarının geleneksel tahmin yöntemlerine göre tercih edilmesinin nedenlerinden bazılarıdır.

Yapay sinir hücreleri (nöronlar); girdiler, ağırlıklar, toplama fonksiyonu, aktivasyon fonksiyonu ve çıkış olmak üzere beş bileşenden oluşur. Girdiler, hücreye dış dünyadan gelen bilgiler olup, veri üzerinde hiçbir matematiksel işlem yapmadan sadece iletilici görevini yerine getirerek verileri bir sonraki aşamaya iletir. Çalışma kapsamında, Konya iline ait doğal gaz tüketimini etkilediği düşünülen 17 ayrı girdi değeri belirlenmiş ve kullanılmıştır. Doğal gaz tüketimine etki eden girdi parametreleri; doğal gaz kullanan abone sayısını temsilen bbs, meteorolojik parametreler (sıcaklık, nem, rüzgar hızı, yağış miktarı, gün öncesi sıcaklıkları ve gün öncesi sıcaklık farkları), bu parametrelerden türetilmiş diğer önemli parametreler (derece gün, hissedilen sıcaklık, windchill) ve doğal gaz satış fiyatı olarak ele alınmıştır.

Ağırlıklar, hücreye gelen bilginin önemini ve hücre üzerindeki etkisini gösterir ve ağırlıkların değiştirilmesiyle ağlardaki öğrenme işlemi sağlanır. Bu çalışmada, yapay sinir ağlarının eğitiminde, az sayıda eğitim adımıyla maksimum başarımına ulaşması ve ilerleyen eğitim adımlarında başarımın değişmemesi nedeni ile Levenberg – Marquardt (LM) öğrenme algoritması tercih edilmiştir. Toplama fonksiyonu, girdi değerlerinin ağırlıklarıyla çarpılarak toplanmasını ve ağa gelen net girdinin bulunmasını sağlar. Toplama fonksiyonundan gelen net girdiyi işleyerek, hücre tarafından bu girdiye karşılık olarak üretilecek çıktının belirlenmesini sağlayan ise

aktivasyon fonksiyonudur. Çalışmada, gizli tabakada Logaritmik Sigmoid ve çıkış tabakasında Pure-linear aktivasyon fonksiyonları kullanılmıştır.

Çıkış değeri ise girdileri kullanarak, öğrenme sonucu aktivasyon fonksiyonu tarafından belirlenen ve dış dünyaya veya başka bir hücreye gönderilmek üzere hazır hale getirilen model çıktısıdır. Çalışmada kullanılan çıkış veri seti Enerya Konya Gaz Dağıtım A.Ş'den temin edilmiş olup, 2005-2015 yılları arasındaki Sm^3 cinsinden günlük doğal gaz tüketim miktarlarından oluşmaktadır. Dağıtım şirketinden alınan geçmiş yıllara ait tüketim verileri, abone (hanehalkı) ve Kademe-1 serbest tüketicilerine (küçük ölçekli işletmeler, ticarethane, resmi daireler, okullar, hastaneler, alışveriş merkezleri vs) ait toplam tüketimlerdir. Her iki grubun da doğal gaz kullanımı öncelikli olarak ısınma, daha sonra sıcak su ve mutfaklarda pişirme amaçlıdır.

Modellemede kullanılan YSA mimarisi ileri beslemeli olarak belirlenmiş ve bu mimariye uygun en iyi ağ modelini geliştirmek üzere farklı denemeler yapılmıştır. YSA mimarilerine bakıldığında genel olarak, istenen çıkışı elde etmek için oluşturulan bir giriş tabakası, çıkışların elde edildiği bir çıkış tabakası ve giriş-çıkış tabakaları arasında en az bir gizli tabaka bulunmaktadır. YSA'lar her ne kadar birden çok gizli tabaka içerebilirlerse de, teorik olarak ispatlanmıştır ki yeterince nörona sahip tek gizli tabaka her zaman birden çok gizli tabakanın yaptığı işi yapabilir. Bu çerçevede, bu çalışmada da tek gizli tabakalı yapay sinir ağları kullanılmış ve gizli tabakadaki nöron sayısı değiştirilerek ağların performansı test edilmiştir.

Uygulamanın ilk kısmında, kullanılan giriş parametreleri ile doğal gaz tüketiminin nasıl değiştiği incelenmiştir. Çıkış veri setini oluşturan Konya ili 2005-2015 yılları arasındaki günlük doğal gaz tüketim değerleri incelendiğinde, doğal gaz kullanan abone sayısı arttıkça yükselişe geçen ve kış aylarında artan, yaz aylarında ise azalan bir profil görülmüştür. Meteorolojik değişikliklerin neden olduğu mevsimsel dalgalanmaların yanı sıra, abone sayısını temsil eden bbs'in de artan doğal gaz tüketimi üzerinde etkisinin büyük olduğu görülmüştür. Dağıtım şirketinden temin edilen geçmiş yıllara bbs ile aynı güne karşılık gelen doğal gaz tüketimleri karşılaştırıldığında sıkı bir ilişki görülmektedir. bbs gibi günlük doğal gaz tüketimini etkileyen en önemli parametrelerden biri de sıcaklık olup, sıcaklıkla ilgili parametreler çalışmada detaylıca ele alınmıştır.

Yapılan analizler göstermiştir ki, hanehalkının ve diğer tüketici gruplarının ısınma amaçlı kullandığı doğal gaz miktarı sıcaklık ile ters orantılı olacak şekilde kış aylarında artmakta, yaz aylarında ise azalarak neredeyse sabit (Mutfakta pişirme ve sıcak su sağlama amaçlarıyla) kalmaktadır. Tüketim ve sıcaklık arasındaki bu güçlü ilişkiyi ağlara daha iyi öğretebilmek için, MGM'den temin edilen minimum-ortalama-maksimum günlük sıcaklık değerlerinin yanında; gün öncesi minimum-ortalama-maksimum sıcaklık değerleri ile gün öncesi minimum-ortalama-maksimum sıcaklık farkı değerleri de modelleme kısmında girdi olarak kullanılmıştır.

Sıcaklık dışında nem, yağış miktarı, rüzgar hızı gibi diğer meteorolojik veriler de tüketim üzerinde etkili olabilmektedir. Sıcaklığın aksine, nem ile doğal gaz tüketimi arasında doğru orantı bulunmaktadır. Havadaki nem oranının yüksek olduğu günlerde tüketim miktarı yüksekken, havadaki nem oranının düşük olduğu sıcak dönemlerde ise tüketim miktarının düşük olduğu görülmüştür. Günlük yağış miktarı ve rüzgar hızının ise sıcaklık ve neme göre tüketim üzerinde belirgin bir etkisi bulunmadığı gözlenmiştir.

Ayrıca, çalışmada birden fazla parametrenin bir araya gelmesiyle ya da parametrelerin türetilmesiyle elde edilen farklı sıcaklık parametreleri de göz önünde bulundurulmuştur. Bunlardan biri ısıtma derece-gün (hdd) olup, ısınma amaçlı kullanılacak doğal gaz tüketim miktarının önemli bir göstergesidir. Tüketim miktarının, Konya için belirlenen 18°C eşik sıcaklığa kadar artıp azaldığı, eşik sıcaklıktan yüksek dış ortam sıcaklıklarında ise neredeyse sabit kaldığı gözlemlenmiştir. Türetilmiş bir diğer parametre ise termometrenin ölçtüğü fiziksel hava sıcaklığından farklı olarak, insan vücudunun hissettiği ve algıladığı sıcaklık olan hissedilen sıcaklıktır. Çalışmada kullanılan hissedilen sıcaklık parametresi belirlenirken, dış ortam sıcaklığı ve nem arasındaki ilişkiyi gösteren ısı indeksi ele alınmıştır. Nem oranının yüksek olduğu kış dönemlerinde hissedilen sıcaklığın daha düşük olduğu ve buna bağlı olarak tüketim miktarının daha yüksek olduğu görülse de diğer sıcaklık parametrelerine göre hissedilen sıcaklığın tüketim üzerindeki etkisi daha az olmuştur. Son olarak, sıcaklıkla beraber ele alındığında rüzgâr hızının tüketim değerleri üzerinde nasıl bir etki yapacağını incelemek üzere windchill değerleri hesaplanmıştır. Windchill ile tüketim değerleri karşılaştırıldığında ise arada yine belirgin bir bağlantının olmadığı gözlemlenmiştir. Bunun nedeni rüzgar ve windchill

değerlerinin dışarıda bulunan kullanıcıların hissettiği sıcaklığı etkilerken, kapalı ortamlardaki kullanıcıların tüketim alışkanlıklarını çok değiştirmemesidir.

Meteorolojik verilerin dışında, serbest piyasa şartlarının temelinde yer alan fiyata göre talebin değişkenlik göstermesi prensibi çerçevesinde doğal gaz satış fiyatı da modelleme kapsamında bir girdi olarak kullanılmış olup, doğal gaz tüketimi üzerinde etkili olmadığı görülmüştür. Normal koşullarda talep edilen enerji miktarının enerji birim bedeline bağlı olarak değişmesi beklenirken, hanehalkının ve diğer kullanıcı gruplarının doğal gaz haricinde alternatif yakıt seçeneklerinin bulunmayışı sebebiyle, doğal gazın bedeli ne olursa olsun kullanıldığı görülmüştür.

Kullanılacak giriş parametrelerinin tüketim üzerindeki etkileri incelendikten sonra uygulamanın ikinci kısmında, farklı YSA yapıları oluşturularak MATLAB'in YSA modülünde (neural network tool) çalıştırılmış ve ağların başarı performansları test edilerek en iyi performans gösteren ağ yapıları seçilmeye çalışılmıştır. Bu çalışma kapsamında, 2005-2015 yıllarına ait 11 senelik giriş-çıkış verisinin 10 senelik kısmı (2005-2014) ağların eğitilmesi için kullanılırken, 1 senelik veri seti ise (2015 yılı) test için kullanılmıştır. Eğitimde kullanılan veri sayısının yüksek olması, ağın daha fazla örnekleme yaparak girdi ve çıktı değerleri arasında daha iyi ilişki kurulmasına olanak sağlamıştır. Ağın başarı performansını test etmek için R^2 , $rRMS$ ve rMB olmak üzere üç ayrı performans kriteri kullanılmıştır.

Modelleme kısmında ilk olarak bütün giriş parametreleri (Çizelge 5.1) kullanılarak ve gizli tabakadaki nöron sayısı (NS) değiştirilerek en iyi YSA modeli elde edilmeye çalışılmıştır. Ağın mimarisi ve giriş-çıkış parametreleri aynı kalacak şekilde, gizli tabakadaki nöron sayısı 10'dan 40'a kadar arttırılarak performans kriterleri değerlendirilmiştir. Gizli tabakadaki nöron sayısı belli bir değeri geçtikten sonra başarı performansının azaldığı, en iyi sonuçların ise 14 gizli tabaka nöron sayılı ağdan elde edildiği görülmüştür. Bütün giriş parametreleri kullanıldığında gizli tabakadaki nöron sayısı 14 olan ağ yapısı, 0,9936 ile en yüksek R^2 ve 0,1076 ile en düşük $rRMS$ değerlerini vermiştir. Günlük tahmini tüketim değerleri toplamının, gerçek tüketim değerlerinin üzerinde çıktığını gösteren pozitif rMB ise 0,0077 olarak kaydedilmiştir. 2015 yılına ait toplam tüketim miktarı (359,7 MSm³), bu ağın [17,14,1] verdiği tahmin sonucunun (362,51 MSm³) altında kalmıştır.

Uygulamanın ikinci kısmında, tüm giriş parametreleri kullanılarak elde edilen en iyi ağ yapısındaki [17,14,1] her bir parametrenin tahmin sonuçları üzerindeki etkisi incelenmiştir. Bu amaçla, bir önceki kısımda elde edilen ağ yapısı değiştirilmeksizin, 1'den 17'ye kadar numaralandırılmış giriş parametreleri sırasıyla çıkartılarak yeni modeller denenmiştir. Bu modellere ait başarı kriterleri karşılaştırılırken de her bir ağ 10 kez koşularak ve 1000 iterasyon yaptırılarak elde edilen sonuçların en iyileri kullanılmıştır. Bu çalışma çerçevesinde, tüketim üzerinde en yüksek etkiye sahip olan parametreler ile birlikte, kullanılmadığı takdirde sonuçları değiştirmeyen veya daha iyi sonuçların elde edilmesini sağlayan parametreler de ortaya çıkarılmıştır. Önceki bölümlerde anlatıldığı gibi, bbs parametresi girişten çıkarıldığında ağın performansı fark edilir derecede azalmıştır. Fakat, gün öncesi maksimum sıcaklık (parametre 6), gün öncesi ortalama sıcaklık farkı (parametre 8), gün öncesi minimum sıcaklık (parametre 10), derece gün (parametre 11) ve rüzgâr etkisi-windchill (parametre 13) parametrelerinin kullanılmadığı ağ yapılarında daha iyi sonuçlar gözlenmiştir.

Uygulamanın üçüncü aşamasında, yukarıda bahsedilen ve çıkarıldığı takdirde sonuçlar üzerinde etkisi olmayan ya da daha iyi sonuçların elde edilmesini sağlayan parametrelerin hepsi girişten çıkarılarak sonuçlar kaydedilmiştir. 6, 8, 10, 11 ve 13 numaralı parametreler çıkarıldıktan sonra, optimum sonuçları elde etmek üzere gizli tabakadaki nöron sayısı değiştirilerek farklı ağ modelleri denenmiştir. Yapılan denemeler göstermiştir ki, sonuçlar üzerinde etkisi olmadığı düşünülen parametreler girişten çıkarıldığında, referans olarak alınan ağın [17,14,1] başarısına aynı gizli tabaka nöron sayısına sahip 12 girişli ağ [12,14,1] yapısıyla da ulaşılmıştır. Fakat sonuçları daha da iyileştirmek adına, gizli tabakadaki nöron sayısı tekrar 8'den 20'ye kadar değiştirilerek bunların en başarılısı olan 15 nöron sayılı yeni ağ [12,15,1] yapısıyla, daha yüksek R^2 (0,9940) ve daha düşük $rRMS$ (0,1046) değerleri elde edilmiştir. Ağın 2015 yılı için vermiş olduğu toplam tahmini tüketim 361,2 MSm³ olurken, 359,7 MSm³ olan fiili tüketimin üzerinde gerçekleşmiş ve rMB 0,0041 olarak kaydedilmiştir.

Şimdiye kadar aktarılan çalışmalar kapsamında elde edilen tüm sonuçlar, test için kullanılan veri setine (2015) aittir. Ağa giriş olarak sokulan tüm parametreler 2015 yılı gerçek verileridir. YSA'larda çıkışın doğruluğunu etkileyen en önemli faktörler ağın yapısı ve giriş parametrelerinin doğruluğudur. Elde edilen ağ yapısının henüz

gerçekleşmemiş bir zamanda kullanılabilmesi ve aynı performansta çıktı üretebilmesi için ağı sunulan giriş değerlerinin de anlamlı olması gerekmektedir. Günümüzde günlük minimum, maksimum ve ortalama sıcaklık tahmini, günlük ortalama nem ve rüzgar hızı tahmini yapan kuruluşlar mevcuttur. Fakat meteorolojik verilerin uzun dönemli tahmin edilmesi hem zordur hem de tahmin edilen verilerin doğruluğu öngörü ufku uzaklaştıkça azalmaktadır. Modelleme çalışmalarının son kısmında, tüm sıcaklık parametrelerinin ve erişilebilirliği daha kolay olan giriş parametrelerinin yer aldığı yeni ağ yapıları denenerek, önceden elde edilen sonuçlara ulaşıp ulaşılamayacağı test edilmiştir. Tüketimi etkileyen en önemli faktörlerin bbs'den sonra sıcaklık ve sıcaklıktan türetilen parametrelerin olduğu; fakat hissedilen sıcaklık, windchill, günlük ortalama rüzgar hızı, günlük toplam yağış miktarı ve doğal gaz satış fiyatının doğal gaz tüketimi üzerinde anlamlı bir etkisinin olmadığı önceki bölümlerde gösterilmişti. Bu parametreler girişten çıkartılıp gizli tabaka nöron sayısı değiştirildiğinde elde edilen sonuçlar göstermiştir ki, gizli tabaka nöron sayısı 15 olan ağ yapısı [12,15,1] yüksek başarı performansı (0,9940; 0,1049) göstererek bir önceki model sonuçlarına (0,9940; 0,1046) ulaşmıştır. Önceki modellerden farklı olarak, bu ağın vermiş olduğu toplam tahmini tüketim fiili tüketimin altında gerçekleşerek 355,71 MSm³ olmuş ve rMB -0,0112 olarak kaydedilmiştir.

Çalışmanın son kısmında, en yüksek başarıyı gösteren yapay sinir ağı ile elde edilen sonuçlar, basit ve çoklu doğrusal regresyon modelleriyle kıyaslanmıştır. Basit doğrusal regresyon modelinde R^2 0,779, çoklu doğrusal regresyon modelinde R^2 0,967 değerini alırken; yapay sinir ağıyla yapılan model sonucu R^2 0,9940 değerini alarak regresyon modellerinden daha yüksek başarıya ulaştığı görülmüştür.

Yapılan modelleme çalışmalarındaki YSA çıktıları fiili tüketim değerleriyle karşılaştırıldığında, ağın 365 gün gibi uzun bir süre için bile gerçeğe yakın çıktı değerleri üretebildiği görülmüştür. Özellikle kış aylarında bu çıktıların gerçekleşen değerlerle örtüşmesi ve sapma oranlarının düşük olması, seçilen ağ yapılarının doğruluğunu ve başarı performansının yüksek olduğunu göstermektedir. Fakat, Mayıs, Ekim, Kasım gibi mevsim geçişlerinin yaşandığı aylarda tahmin sapmalarının diğer aylara göre daha fazla olduğu gözlenmiştir. Bu aylardaki doğal gaz tüketim miktarları çok yüksek olmayıp, tahmin edilen aylık miktarlar planlamada büyük sapmalara neden olmayacaksa da, günlük doğal gaz talebinin doğruluğunu arttırmak için mevsim

geçişlerinin de özel olarak ele alındığı ve yılın farklı dönemlerinde farklı modellerin kullanıldığı bir tahmin modelinin yapılmasının da bir başka çalışma konusu olabileceği değerlendirilmektedir. Bu çalışmanın devamında, hafta sonu ve tatil günlerinin daha detaylı olarak ele alındığı farklı talep tahmin çalışmaları da yapılarak sonuçların geliştirilmesine katkı sağlanabilir.

KAYNAKLAR

- Adıyaman, F.,** (2007). *Talep Tahmininde Yapay Nöron Ağlarının Kullanılması* (Yüksek Lisans Tezi). İstanbul Teknik Üniversitesi, Fen Bilimleri Enstitüsü, 2007.
- Bağırkan, Ş.,** (1982). *İstatistiksel Analiz*, İstanbul: Önsöz Basım ve Yayıncılık
- Barutçu, B.,** (2013). *Signal Processing and Analysis in Renewable Energy Systems, Prediction Problem*, Ders Notları, İTÜ Enerji Enstitüsü
- BOTAŞ,** (2014). 2014 Yılı Sektör Raporu, Boru Hatları ile Petrol Taşıma A.Ş.
- Box, G.E., Jenkins, G.M. and Reinsel, G.C.,** (2008). *Time Series Analysis, Forecasting and Control*, Fourth Edition, John Wiley & Sons, Inc.
- Bulut H., Büyükalaca O. ve Yılmaz T.,** (2007). Türkiye İçin Isıtma Ve Soğutma Derece-Gün Bölgeleri, *ULIBTK'07 16. Ulusal Isı Bilimi ve Tekniği Kongresi*, Kayseri
- Çağlar, T.,** (2007). *Talep Tahmininde Kullanılan Yöntemler ve Fens Teli Üretimi Yapan Bir İşletmede Uygulanması* (Yüksek lisans tezi). Kırıkkale Üniversitesi, Fen Bilimleri Enstitüsü, Kırıkkale
- Demir, H. ve Gümüšoğlu, Ş.,** (1994). *Üretim / İşlemler Yönetimi*, Beta Basım Yayın Dağıtım A.Ş., İstanbul.
- EİE,** (1991). *Binalarda Enerji Tasarrufu Serisi 2*, Elektrik İşleri Etüt İdaresi Genel Müdürlüğü, Ankara
- EPDK,** (2015). Doğal Gaz Piyasası 2015 Yılı Sektör Rapor, Enerji Piyasası Düzenleme Kurumu Strateji Geliştirme Dairesi Başkanlığı, Ankara 2016
- ETKB** (2016). Dünya ve Ülkemiz Enerji ve Tabii Kaynaklar Görünümü, Strateji Geliştirme Dairesi Başkanlığı, Ankara 2016
- Fausett, L.,** (1994). *Fundamentals of Neural Networks Architectures, Algorithms, and Applications*
- Hamzaçebi, C.,** (2011). *Yapay Nöron Ağları, Tahmin amaçlı kullanımı Matlab ve Neurosolutions uygulamalı*, Ekin Yayınevi, Bursa, 2011.
- Hanke, J.E. ve Reitsch A. G.,** (1992). *Business Forecasting*, Fourth Edition, Allyn and Bacon, Boston.

- Haykin, S.**, (1999). *Neural Networks a Comprehensive Foundation*, Second Edition, Prentice Hall, 1999.
- Karahan, M.**, (2011). *İstatistiksel Tahmin Yöntemleri: Yapay Nöron Ağları Metodu ile Ürün Talep Tahmini Uygulaması* (Doktora tezi). Selçuk Üniversitesi Sosyal Bilimler Enstitüsü, 2011.
- Kartalopoulos, S.V.**, (1996). *Understanding Neural Networks and Fuzzy Logic. Basic Concepts and Applications*, New York: IEEE Press.
- Levenberg, K.**, (1944). *A Method for the Solution of Certain Problems in Least Squares*, Quarterly Applied Math. 2, 164-168.
- Marquardt, D.**, 1963: An Algorithm for Least Squares Estimation of Nonlinear Parameters, SIAM Journal Applied Math., 11, 431-441.
- Masters, T.**, (1993). *Practical Neural Network Recipes in C++*, Academic Pres, USA.
- MESOR**, (2009). *Management and Exploitation of Solar Resource Knowledge*, D 1.1.3 Report on Benchmarking of Radiation Products, CA – Contract No. 03866
- Monks, J.G.**, (1996). *İşlemler Yönetimi Teori ve Problemler*. Nobel Yayın Dağıtım, Ankara.
- Naylor, T.H., Seaks, T.G. and Wichern, D.W.**, (1972). *Box-Jenkins Methods: An Alternative to Econometric Models*, International Statistical Review, Vol. 40, No. 2.
- Orhunbilge, N.**, (1999). *Zaman Serisi Analizi Tahmin ve Fiyat İndeksleri*, İstanbul Üniversitesi İşletme Fakültesi Yayınları, İstanbul.
- Öztemel, E.**, (2012). *Yapay Sinir Ağları*. Nisan 2012, İstanbul.
- Satman A. ve Yalcinkaya N.**, (1999). *Heating And Cooling Degree-Hours For Turkey*, Energy 24 (1999) sf. 833–840
- Sensoy, S., Eken, M., Sağır, R. ve Ulupınar, U.**, (2007). *Türkiye Uzun Yıllar Isıtma Ve Soğutma Gün Dereceleri*, Devlet Meteoroloji İşleri Genel Müdürlüğü, Ankara
- Simon, H. A.**, (1983). *Machine Learning An Artificial Intelligence Approach*, Chapter 2, Why Should Machines Learn?. Springer-Verlag, Berlin Heidelberg, 1983
- Steadman, R.G.**, (1979). *The Assessment of Sultriness. Part I: A Temperature-Humidity Index Based On Human Physiology And Clothing Science*. J. Appl. Meteor., 18, 861-873.
- Şehirlioğlu, A.K.**, (2008). *Regresyon Analizi Bölüm 1-2*, Ders Notları, Dokuz Eylül Üniversitesi, 2008

- Şentuna, B.**, (2013). *Regresyon Analizi*, Ders Notları, Balıkesir Üniversitesi
- Şıklar, E.**, (2003). *İstatistik, Bölüm 11, Basit Doğrusal Regresyon*, Anadolu Üniversitesi Yayını No: 1448
- ŞİD**, (2004). *BOTAŞ İletim Şebekesi İşleyiş Düzenlemelerine İlişkin Esaslar*, 25561 Sayılı Resmi Gazete
- Tekin, M.**, (2009). *Üretim Yönetimi*, Cilt 1 (6. Baskı). Konya: Günay Ofset.
- Toktaş, İ. ve Aktürk, N.**, (2004). *Makine Tasarım İşleminde Kullanılan Yapay Zeka Teknikleri ve Uygulama Alanları*, Makine Teknolojileri Elektronik Dergisi, 2004.
- Tolon, M. ve Tosunoğlu N.**, (2008). *Tüketici Tahmini Verilerinin Analizi: Yapay Nöron Ağları ve Regresyon Karşılaştırması*, Gazi Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi 10 / 2 (2008). s. 247-259.
- Topçu, G.Y.**, (2013). *Türkiye Doğal Gaz Tüketim Tahmini* (Yüksek lisans tezi). Ankara Üniversitesi, 2013.
- TP**, (2015). *Ham Petrol ve Doğal Gaz Sektör Raporu*, Türkiye Petrolleri Strateji Geliştirme Daire Başkanlığı, Aralık 2015, s.4-5,14-16,25-28.
- Ünal, H.H.**, (2014). *Türkiye doğal gaz iletim sistemine üçüncü taraf erişimi 2007-2013*, Enerji Hukuku araştırma enstitüsü, Ankara, Mayıs 2014, s.11-13.
- Üreten, S.**, (2005). *Üretim/İşlemler Yönetimi, Stratejik Kararlar ve Karar Modelleri*, 5. Baskı, Gazi Kitabevi, Ankara.
- Yüksek, A.G.**, (2007). *Hava Kirliliği Tahmini YSA Çoklu Regresyon* (Doktora tezi). Cumhuriyet Üniversitesi, Sosyal Bilimler Enstitüsü, Sivas.
- Url-1** http://www.eie.gov.tr/eie-web/turkce/en_tasarrufu/uetm/ts13.html, erişim tarihi 19.10.2016.
- Url-2** <http://www.botas.gov.tr/>, erişim tarihi 31.08.2016.
- Url-3** <http://enerjiuzmani.blogspot.com/>, erişim tarihi 31.08.2016.
- Url-4** <http://www.tpao.gov.tr/tp5/?tp=m&id=84>, erişim tarihi 28.08.2016.
- Url-5** <http://www.ibrahimcayiroglu.com/dokumanlar/ilerialgoritmaanalizi/ilerialgoritmaanalizi-5.hafta-yapaysiniraglari.pdf> erişim tarihi 31.08.2016.
- Url-6** <https://www.mgm.gov.tr/genel/sss.aspx?s=hissedilensicaklik>, erişim tarihi 31.03.2017.
- Url-7** http://www.wpc.ncep.noaa.gov/html/heatindex_equation.shtml erişim tarihi 31.03.2017.
- Url-8** http://www.nws.noaa.gov/om/cold/wind_chill.shtml, erişim tarihi 31.03.2017.

ÖZGEÇMİŞ

Ad-Soyad : Burcu AKIN
Doğum Tarihi ve Yeri : 25.12.1988 / Kocaeli
E-posta : ilgenburcuakin@gmail.com

ÖĞRENİM DURUMU:

- **Lisans** : 2012, Hacettepe Üniversitesi, Mühendislik Fakültesi, Kimya Mühendisliği

MESLEKİ DENEYİM VE ÖDÜLLER:

- 2012-2016 yılları arasında Enerya Gaz Ticaret A.Ş.'de Gaz Ticaret Uzmanı olarak çalıştı.
- 2015 yılında STFA inovasyon çalışmaları kapsamında, “Dağıtım Şirketleri İçin Talep Tahmin Modeli” adlı inovasyon projesi geliştirdi.
- 2016 yılından itibaren Enerya Gaz Ticaret A.Ş.'de Gaz Ticaret Yöneticisi olarak çalışmaya devam etmektedir.