

T.C.
İSTANBUL ÜNİVERSİTESİ
SOSYAL BİLİMLER ENSTİTÜSÜ
İŞLETME ANABİLİM DALI
ÜRETİM BİLİM DALI

DOKTORA TEZİ

SANAYİDEKİ ENERJİ YÜK TAHMİN
MODELLERİ

ALİ NADİR KAPKIN

2502090319

TEZ DANIŞMANI
PROF. DR. NECDET ÖZÇAKAR

İSTANBUL 2018



T.C.
İSTANBUL ÜNİVERSİTESİ
SOSYAL BİLİMLER ENSTİTÜSÜ

DOKTORA
TEZ ONAYI



ÖĞRENCİNİN;

Adı ve Soyadı : ALİ NADİR KAPKIN Numarası : 2502090319
Anabilim Dalı / Anasanat Dalı / Programı : ÜRETİM Danışmanı : PROF.DR.NECDER ÖZÇAKAR
Tez Savunma Tarihi : 19.12.2018 Saati : 15:30
Tez Başlığı : SANAYİDEKİ ENERJİ YÜK TAHMİN MODELLERİ.

TEZ SAVUNMA SINAVI, İÜ Lisansüstü Eğitim-Öğretim Yönetmeliği'nin 50. Maddesi uyarınca yapılmış, sorulan sorulara alınan cevaplar sonunda adayın tezinin KABULÜNE OYBİRLİĞİ / OYÇOKLUĞUyla karar verilmiştir.

JÜRİ ÜYESİ	İMZA	KANAATİ (KABUL / RED / DÜZELTME)
PROF.DR.NECDER ÖZÇAKAR		KABUL
PROF.DR.ALPAZ BARAY		KABUL
PROF.DR.SELİM ZAIM		KABUL
DOÇ.DR.ÖZLEM AKÇAY KASAPÖĞLU		
DR.ÖĞR.ÜYESİ HALİT ALPER TAYALI		KABUL

YEDEK JÜRİ ÜYESİ	İMZA	KANAATİ (KABUL / RED / DÜZELTME)
DR.ÖĞR.ÜYESİ SÜNDÜZ DAĞ		KABUL
DR.ÖĞR.ÜYESİ ERDAL YILMAZ		

ÖZ

SANAYİDEKİ ENERJİ YÜK TAHMİN MODELLERİ

ALİ NADİR KAPKIN

Bu tez çalışmasında yer alan Organize Sanayi Bölgesi'nde kullanılan elektrik enerjisinin tahminlemesi Arima , Double Seasonal Holt Winter ve Yapay Sinir Ağları ile modellenmiştir. Hangi Modelin Organize Sanayi Bölgesi'nin tüketimini en iyi tahmin ettiği sorusunun cevabı aranmıştır. Organize Sanayi Bölgesi'nin 2011-2017 yılları arasındaki elektrik tüketimi saatlik olarak incelenmiştir. Mevcut verilere göre modeller oluşturulmuş, ve bu Organize Sanayi Bölgesi için en iyi model yaratılmaya çalışılmıştır. Oluşan yeni model elektrik alım satım kontratları yaparken Organize Sanayi Bölgesi Yönetimi'ne güçlü bir yol gösterici olacaktır. Bunun yanında doğru talep Elektrik Üreticileri'nin kaynaklarının optimum seviyede kullanmasını sağlayacaktır.

Anahtar Kelimeler: Talep tahmini, Arima, Holt Winters, yapay sinir ağları, elektrik talebi

ABSTRACT
SHORT TERM LOAD FORECAST IN INDUSTRY ZONE

ALİ NADİR KAPKIN

In this thesis, the estimation of the electrical energy used in the Organized Industrial Zone was investigated by Arima, Double Seasonal Holt Winter and Artificial Neural Networks. The results were compared with each other. The answer to the question of which model best estimates the electric consumption of the Organized Industrial Zone was thought. The electricity consumption between the years of 2011-2017 of the Organized Industrial Zone was examined in hourly. According to the available data, models have been created and the best model for this Organized Industrial Zone has been tried to be created. The new model will be a powerful guide to Organized Industrial Zone Management while making electricity purchase contracts. In addition, the right demand will ensure that Electricity Producers use their resources at the optimum level.

Keywords: Demand forecasting, Arima, Holt Winters, artificial neural networks, electricity demand

ÖNSÖZ

Bu çalışmada Türkiye'nin Batısında bulunan Orta Ölçekli Organize Sanayi Bölgesi'nde kullanılan elektrik enerjisinin kısa dönem elektrik yük talep tahmini yapılmıştır.

Literatürde konuyla ilgili yapılan ispat, karşılaştırma ve analiz çalışmaları detaylı bir şekilde taranmıştır. Diğer çalışmalardan farklı olarak Organize Sanayi Bölgesi için Kısa Dönem Yük Tahmin'i üç farklı yöntemle birbirleriyle karşılaştırılarak yapılmıştır. Organize Sanayi için Kısa Dönem Yük Tahmin yöntemi için en uygun model geliştirilmiştir.

Bu tez konusunun tayininde, araştırma aşamasında ve tamamlanmasında desteğini esirgemeyen değerli hocam ve tez danışmanım Sayın Prof. Dr. Necdet Özçakar'a, tez izleme kurulu üyelerim Sayın Prof. Dr. Alp Baray'a ve Sayın Prof. Dr. Selim Zaim'e ayırdıkları kıymetli zamanlarından ötürü teşekkür ederim.

Bugünlere gelmemde büyük emek sarf eden özellikle annem Emine Kapkın ve babam M. Rıza Kapkın'a katkılarından dolayı teşekkür ederim.

Ali Nadir KAPKIN

İstanbul, 2018

İÇİNDEKİLER

ÖZ	ii
ABSTRACT	iv
İÇİNDEKİLER.....	vi
ŞEKİLLER.....	ix
TABLolar	xii
KISALTMALAR LİSTESİ.....	xiii
GİRİŞ	1

BİRİNCİ BÖLÜM

ELEKTRİK ENERJİSİ

1.1	Elektrik Enerjisi	3
1.1.1	Elektrik Enerjisinin Üretimi	3
1.1.1	Enerji Üretim Kaynakları.....	4
1.1.2	Elektrik Enerjisinin İletimi.....	9
1.1.3	Elektrik Enerjisi Dağıtımı	9
1.1.4	Elektrik Enerjisi Tedarik Zinciri	9
1.2	Elektrik Sistem Yüğü	11
1.2.1	Sistem Yüğüne Etki Eden Faktörler.....	12
1.3	Elektrik Piyasası.....	13
1.3.1	Geleneksel Elektrik Piyasası	14
1.3.2	Liberal Elektrik Piyasası	15
1.4	Elektrik Piyasası İşleyişı	16
1.4.1	Perakende Elektrik Piyasası	16
1.4.2	Toptan Elektrik Piyasası	17
1.4.3	Türkiye Enerji Sektörünün Gelişimi	18
1.5	Elektrik Yüğü Tahmin Modelleri.....	21
1.6	Elektrik Yüğü Tahmin Kategorileri	22
1.6.1	Uzun süreli yüğü tahmini (Long-Term Load Forecasting LTLF).....	22
1.6.2	Orta vadeli yüğü tahmini (Mid-Term Load Forecasting-MTLF).....	22

1.6.3	Kısa Vadeli Yük Tahmini (Short Term Load Forecasting- STLTF).....	23
1.7	Kısa Vade Yük Tahmin İçin Kullanılan Yöntemler	23
1.7.1	İstatiksel Teknikler.....	24

İKİNCİ BÖLÜM

ZAMAN SERİLERİ

2.1	Zaman Serilerinde Durağanlık Kavramı	29
2.1.1	Durağan ve Durağan Olmayan Seri	29
2.2	Otoregresif Model AR (p).....	31
2.3	Hareketli Ortalama Modeli (MA)	32
2.4	Otoregresif Hareketli Ortalama Süreci (ARMA).....	32
2.5	Box – Jenkins Yaklaşımı (ARIMA)	33
2.5.1	ARIMA Modelinin Metodolojisi	34
2.5.2	Otokorelasyon fonksiyonu (ACF).....	36
2.5.3	Kısmi Otokorelasyon Fonksiyonu (PACF).....	37
2.6	ARIMA Metoduyla Organize Sanayi Bölgesi Verilerinin Tahminlemesi	39
2.6.1	Serilerin Durağanlaştırılması	42
2.6.2	ARİMA Modelinin Uygulanması	47
2.7	Double Seasonal Holt Winters Metoduyla Verilerin İncelenmesi	52

ÜÇÜNCÜ BÖLÜM

YAPAY SİNİR AĞLARI

3.1	Yapay Sinir Ağlarının Gelişimi	58
3.2	Aktivasyon Fonksiyonlarının Tanıtılması.....	61
3.2.1	Adım Fonksiyonu (Step-Wise)	62
3.2.2	Lineer Fonksiyon	64
3.2.3	Sigmoid Fonksiyonu	65
3.2.4	Tanh Fonksiyonu.....	67
3.2.5	Relu Fonksiyonu	69
3.2.6	Hata Kriterleri	71
3.2.7	Optimizasyon Algoritmaları	72
3.3	Lstm Blokları (Long-Short-Term Memory).....	77
3.4	İleri Beslemeli Sinir Ağı (Feedforward ANN).....	82

3.5	Konvolüsyonel Sinir Ağı (Convolutional Neural Network)	85
3.6	Organize Sanayi Verilerinin Yapay Sinir Ağları Modeliyle İncelenmesi.....	86
SONUÇ VE ÖNERİLER		89
KAYNAKÇA.....		92



ŞEKİLLER LİSTESİ

Şekil 1: Türkiye Elektrik Enerjisi Üretiminin Kaynaklara Göre Dağılımı.....	7
Şekil 2: Yenilenebilir Enerji Kaynakları'nın Dağılımı	8
Şekil 3: Enerji Tedarik Zinciri.....	10
Şekil 4: Ortalama Durağanlık	30
Şekil 5: Varyans Durağanlık	30
Şekil 6: Kovaryans Durağanlık.....	31
Şekil 7: İşlenmemiş Veri	39
Şekil 8: Temizlenmiş Veriler.....	40
Şekil 9: Kural Dışlıklar.....	41
Şekil 10: Haftanın Günlerine göre elektrik kullanımı	42
Şekil 11: On Haftalık Verilerin trend ve mevsimsellikten arındırılmış hali	44
Şekil 12: Artık Serinin Ortalaması ve Standart Sapması	46
Şekil 13: ACF ve PACF grafiği	47
Şekil 14: 1.Durum için seçilen verilerin 10 haftalık grafiği	48
Şekil 15: Ortalama Mutlak Hata Yüzdesi	48
Şekil 16: Saatlik Ortalama Mutlak Hata Yüzdesi	49
Şekil 17: 2.Durum için verilen Dataların 8 haftalık grafiği.....	50
Şekil 18: Ortalama Mutlak Hata Yüzdesi	50

Şekil 19: Saatlik Ortalama Mutlak Hata Yüzdesi	51
Şekil 20: Çarpımsal Çift Mevsimsellikli Holts Winters Ortalama Mutlak Hata Yüzdesi.....	55
Şekil 21: Saatlere Göre MAPE dağılımı.....	56
Şekil 22: Toplamsal Çift Mevsimsellikli Holts Winters Ortalama Mutlak Hata Yüzdesi.....	56
Şekil 23: Saatlere Göre MAPE dağılımı.....	57
Şekil 24: İnsan nöronu ile yapay nöronun karşılaştırılması.....	59
Şekil 25: Basit Yapay Sinir Ağı Hücresi	60
Şekil 26: Basit hücre yapısı	61
Şekil 27: Adım Fonksiyonu	62
Şekil 28: Adım Fonksiyonunun Türev Grafiği.....	63
Şekil 29: Lineer Fonksiyon.....	64
Şekil 30: Lineer Fonksiyon Türevi	65
Şekil 31: Sigmoid Fonksiyonu	66
Şekil 32: Sigmoid Fonksiyonu Türevi.....	67
Şekil 33: Tanh Fonksiyonu	68
Şekil 34: Tanh Türev Fonksiyonu	69
Şekil 35: Relu Fonksiyonu	70
Şekil 36: Relu Fonksiyonu Türevi.....	70
Şekil 37: İki Boyutlu Giriş Vektörünün Matematiksel İfadesi.....	73

Şekil 38: Hata Optimizasyonunun Gösterimi	74
Şekil 39: Adam algoritması	76
Şekil 40: LSTM Bloğu (Long Short Term Memory)	77
Şekil 41: Seri Bağlanmış LSTM Blokları.....	78
Şekil 42: LSTM Çalışma prensibi 1.aşama	79
Şekil 43: LSTM 2. aşama	80
Şekil 44: LSTM 3. Aşama	81
Şekil 45: LSTM 4. Aşama	81
Şekil 46: LSTM 5. Aşama	82
Şekil 47: Üç Gizli Katmanlı İleri Beslemeli Sinir Ağı Örnek 1	83
Şekil 48: Üç Gizli Katmanlı İleri Beslemeli Sinir Ağı Örnek 2	84
Şekil 49: Konvolüsyonel Sinir Ağı (CNN).....	85
Şekil 50: Yapay Sinir Ağları Modeli	88

TABLÖLER LİSTESİ

Tablo 1: Dünyadaki Elektrik Enerjisi Kaynaklarının Son 10 Yıldaki Değişimi.....	4
Tablo 2: Enerji Kaynaklarının Sınıflandırılması.....	6
Tablo 3: Türkiye Elektrik Kaynaklarına Göre Elektrik Üretim Miktarı	7
Tablo 4: Yenilenebilir Enerji Kaynakları'na Göre Elektrik Üretim Miktarı	8
Tablo 5: Sonuçlar	89

KISALTMALAR LİSTESİ

ACF	: Otokorelasyon Fonksiyonu
AI	: Artificial Intelligent (Yapay Zeka)
AIC	: Akaike Bilgi Kriteri
AR	: Otoregresif Model
ARIMA	: Otoregresif entegre hareketli ortalama modeli
ARMA	: Otoregresif hareketli ortalama modeli
DSO	: Dağıtım Sistemi Operatörü
EGS	: Elektrik Güç Sistemi
EPİAŞ	: Enerji Piyasa İşletmesi Anonim Şirketi
GÖP	: Gün Öncesi Piyasası
GW	: Gigawatt
GWe	: Gigawatt elektrik
İSO	: İletim Sistemi Operatörü
LSTM	: Long Short Term Memory
LTLF	: Uzun Dönem Yük Tahmini
MA	: Hareketli Ortalama Süreci
MAE	: Ortalama Mutlak Hata
MAPE	: Ortalama Mutlak Hata Yüzdesi
MSE	: Ortalama Kareli Hata
MTLF	: Orta Dönem Yük Tahmini
PACF	: Kısmi Otokorelasyon Fonksiyonu
RMSE	: Kök Kareler Karesi
SD	: Standart Sapma
SGD	: Stochastic Gradient Descent Algoritması
SMF	: Sistem Marjinal Fiyatı
STLF	: Kısa Dönem Yük Tahmini
TEİAŞ	: Türkiye Elektrik İletim Anonim Şirketi
YSA	: Yapay Sinir Ağı

GİRİŞ

Enerji planlaması ve yönetimi, tüm dünyadaki çoğu ülke için önemlidir. Sanayi devriminin başlangıcından bu yana, ekonomik büyümenin ana kaynağı elektriktir. Dolayısıyla, elektrik ihtiyaçlarını öngörmek için metodolojiler ve prosedürler oluşturmanın gerekliliği öne çıkmıştır. Bu konu hem akademisyenler, hem hükümet hem de elektrik şirketleri için önemli bir konu olmuştur.

Elektrik talep tahmin modelleri genel olarak üç kısma ayrılmaktadır.

1. Uzun Dönem Yük Tahmini (Long Term Load Forecasting-LTLF)
2. Orta Dönem Yük Tahmini (Mid-Term Load Forecasting-MTLF)
3. Kısa Dönem Yük Tahmini (Short Term Load Forecasting-STLF)

Uzun Vadeli Elektrik Talebi Yük Tahmini, elektrik güç sistemlerinin iyi planlanması ve genişletilmesinin önemli bir parçasıdır. Aslında, yeni nesil tesislerin inşasının planlanmasında, bir ülkenin elektrik matrisinin geliştirilmesinde ve iletim hatlarının genişletilmesinde önemli bir rol oynamaktadır.

Orta Vadeli Elektrik Talebi Yük Tahminleri ise bakım programları, ara dönem hidrotermal koordinasyon, yeterlilik değerlendirmesi, sınırlı enerji birimlerinin yönetimi, düşük maliyetli yakıt alım stratejilerinin geliştirilmesi gibi birçok alanda kullanılmaktadır.

Günümüzde elektrik iletim ve dağıtım sistemlerinde depolama mevcut değildir. En iyi güç sistemi çalışması için elektrik üretimi elektrik yükünü takip etmelidir. Üretim, iletim ve dağıtım programları elektrik yükünü tahmin etmek için bazı yöntemler kullanılmaktadırlar. Böylece elektrik altyapısını verimli, güvenli ve ekonomik olarak kullanırlar.

Üretim tesisleri, Kısa Vadeli Elektrik Yük Tahminini yakın gelecekteki yük talebini karşılamak ve üretim kaynaklarını planlamak üzere kullanır.

İletim araçları ise, talepten daha fazla güç çekilmesi durumunda oluşabilecek tıkanıklığı ve aşırı yüklenmeleri azaltmak için güç akışını optimize etmek amacıyla Kısa Vadeli Yük Tahmini'ni kullanmaktadır.

Kısa dönemli tahminler bir saatten bir haftalığa kadar olan süreci kapsamaktadır. Gün içerisinde elektrik enerji ihtiyacının sürekli olarak değişmesinden dolayı devreye giren ya da devreden çıkan güç sistemleri sayısı değişmektedir.

Güç sistemlerinin tahminlere göre işletilmesi ile kullanıcılara ekonomik ve kaliteli enerji sağlanabilir. Verimli enerji planlaması enerji maliyetlerini düşürür.

Çalışmada Organize Sanayi Bölgesi'nin haftalık elektrik enerji ihtiyacı incelenmiştir. Amaç haftalık enerji ihtiyacını optimum olarak tahmin etmektir. Bu veriler elektrik alım satım kontratları yaparken güçlü bir yol gösterici olur.

BİRİNCİ BÖLÜM

ELEKTRİK ENERJİSİ

1.1 Elektrik Enerjisi

Elektrik enerjisi, insanların kullanımı için en uygun enerji biçimidir. Elektrik enerjisi kullanımı kolaydır ve bir yerden başka bir yere hareket eder, ancak büyük miktarlarda depolanması neredeyse imkansızdır. Sanayi’de, işletmelerde, konutlarda, çoğu cihazın çalıştırılmasında, ulaşımda, hatta ısıtmada bile kullanılmaktadır. Elektriğin üretildiği noktadan son kullanıcıya ulaştığı ana kadar olan süreçler alt bölümde açıklanacaktır.

1.1.1 Elektrik Enerjisinin Üretimi

Elektrik enerjisi, nükleer enerji, fosil yakıtlar (kömür, gaz ve petrol), yenilenebilir enerji kaynakları (rüzgar, güneş enerjisi) gibi çeşitli enerji kaynaklarından elde edilen enerjinin elektriğe dönüştürülmesiyle üretilir. Geleneksel enerji üretim tesislerinin yanı sıra, daha yakın zamanlarda biyoenerji, hidroelektrik, rüzgar, güneş ve jeotermal enerji gibi Yenilenebilir Enerji Kaynaklarının kullanımı sürekli olarak artmaktadır. Elektrik, şebeke üzerinden son tüketiciye iletilir. Elektrik enerjisi birincil bir enerji kaynağı değildir, bunun yerine bir enerji para birimidir. Birincil enerji (rüzgar veya doğal gaz gibi), kolay kullanım ve iletim için elektrik yapmak üzere bir elektrik santraline gider.

Son 15 yılda enerji kaynaklarının tüketiminde görülmemiş bir değişim görülmüştür. Yenilenebilir enerji pazarında beklenmeyen yüksek oranda bir büyüme, gelişmekte olan ülkelerde yatırım, yeni kapasitelerin geliştirilmesi enerji üretim matrisini dinamik bir yapı haline getirdi. Bunun sonucunda fiyatlar düştü, ekonomik büyüme ve sera gazı etkisi arttı.

Elektrik piyasası liberalleştikçe sera etkisi ve çevre sorunlarından dolayı hükümetler enerji sektöründeki yatırım politikalarını değiştirmektedir. Önceliği Yenilenebilir Enerji Kaynakları’na vermektedir. Yenilenebilir Enerji yatırımlarının büyümesi aynı


zamanda enerji üretim öngörüsünde belirsizliklere de sebep olmaktadır. Belirsizliğe sebep olan etkilere örnek verecek olursak, sıcaklık, lokasyon, hava durumu v.b.

Yenilenebilir Enerji Kaynakları'nın doğası gereği var olan belirsizliklerden dolayı enerji üretim piyasalarındaki üretim planlamalarının önemi artacaktır. Konvansiyonel enerji üretiminde var olan üretim planlamasındaki yüksek öngörülebilirlik yetisi etkisini yitirecektir. Bu durum enerji matrisinin yönetiminde değişiklere de sebep olacaktır.

Dünyadaki Elektrik Kaynakları'nın Son 10 yıldaki değişimi Tablo1'de gösterilmiştir. (World Energy Council, 2016)

Tablo 1 Dünyadaki Elektrik Enerjisi Kaynaklarının Son 10 Yıldaki Değişimi

FIGURE 1: COMPARATIVE PRIMARY ENERGY CONSUMPTION OVER THE PAST 15 YEARS



1.1.1 Enerji Üretim Kaynakları

Energileri elde etmek için de enerji kaynakları kullanılır. Elektrik enerjisine dönüştürülebilen enerjilerin belli başlı kaynakları da şunlardır:

1. Termik kaynaklar
2. Hidrolik kaynaklar
3. Nükleer Kaynaklar

4. Diğer kaynaklar (Güneş, rüzgâr, jeotermal vb.)

1.1.1.1 Termik Kaynaklar

Termik kaynaklar, gerekli koşullar sağlandığında ısı enerjisi meydana getirebilen katı, sıvı ve gaz şeklindeki yakıtlardır Çalışma prensibi fosil yakıtlar kullanılarak sıcak sudan elde edilen basınç ile buhar türbininin dönmesiyle oluşan akımdır. Bu fosil yakıtlar;

Kullanım Sırasına Göre;

- 1.Kömür
- 2.Petrol Ve Motorin
- 3.Doğal gaz
4. Talaş
- 5.Çöpten üretilmiş metan gazıdır.

1.1.1.2 Hidrolik Kaynaklar

Su gücü ile elektrik enerjisi üretimine hidroelektrik enerji denir. Hidroenerji, deniz seviyesinin üstünde bulunan su kaynaklarının belirli bir yüksekten aşağıya akması ile enerjiyi türbin yardımı ile kullanılarak mekanik enerjiye dönüştürme işlemine denir. Bu meydana gelen mekanik enerji de suyun akışının olduğu kısımda bulunan jeneratörler ile elektrik enerjisine dönüştürülür ve hidroelektrik enerjisi oluşur. Hidroelektrik enerjide sistemler genelde suyun döküldüğü anda ki mesafesine göre ayarlanır ve oluşur.

1.1.1.3 Nükleer Kaynaklar

Uranyum gibi radyoaktif elementlerin atomlarının nükleer santrallerin reaktörlerinde kontrollü bir şekilde parçalanması sonucu meydana gelen ısı enerjisinden elektrik enerjisi üretilmesi için kullanılan bir kaynaktır.


1.1.1.4 Diğer Kaynaklar

Güneş enerjisi, rüzgar kuvveti, Jeotermal enerji, gel-git ve dalga kuvveti diğer enerji kaynaklarındandır.

Tablo 2’de Enerji Kaynakları gösterilmiştir.

Tablo 2 Enerji Kaynaklarının Sınıflandırılması

Enerji Kaynakları	
Kullanışlarına Göre	Dönüştürülebilirliklerine Göre
1-Yenilenemez (Tükenir) <i>a) Fosil Kaynaklı</i> • Kömür • Petrol • Doğalgaz <i>b) Çekirdek Kaynaklı</i> • Uranyum • Toryum	1-Birincil (Primer) • Kömür • Doğalgaz • Petrol • Nükleer • Biyokütle • Hidrolik • Güneş • Rüzgâr • Med-Cezir (Gel-Git)
2- Yenilenebilir (Tükenmez) • Güneş • Jeotermal • Rüzgâr • Biyokütle • Hidrolik • Hidrojen • Med-Cezir (Gel-Git)	2-İkincil (Sekonder) • Elektrik, Benzin, Motorin • İkincil Kömür • Kok, Petrokok • Hava Gazı • Sıvılaştırılmış Petrol Gazı (LPG)




Şekil 1 Türkiye Elektrik Enerjisi Üretiminin Kaynaklara Göre Dağılımı

Tablo 3 Türkiye Elektrik Kaynaklarına Göre Elektrik Üretim Miktarı

KAYNAK	ÜRETİM (GWh)	KATKISI (%)
İthal Kömür	51.118,1	17,20
Taşkömürü + Asfaltit	5.663,8	1,91
Linyit	40.694,4	13,69
Doğal Gaz	110.490,0	37,17
Sıvı Yakıtlar	1.199,9	0,40
Barajlı	41.312,6	13,90
D.Göl ve Akarsu	16.905,9	5,69
Rüzgar	17.903,8	6,02
Yenilenebilir Atık+Atık	2.124,0	0,71
Atık Isı	848,3	0,29
Jeotermal	6.127,5	2,06
Güneş	2.889,3	0,97
TOPLAM	297.277,5	100,00

**2017 YILI YENİLENEBİLİR
KAYNAKLARDAN ELEKTRİK ENERJİSİ
ÜRETİMİNİN DAĞILIMI**



Şekil 2 Yenilenebilir Enerji Kaynakları'nın Dağılımı

Tablo 4 Yenilenebilir Enerji Kaynakları'na Göre Elektrik Üretim Miktarı

	GWh	%
YENİLENEBİLİR ATIK+ATIK	2.124,0	2,43
RÜZGAR	17.903,8	20,52
GÜNEŞ	2.889,3	3,31
BARAJLI	41.312,6	47,34
D.GÖL VE AKARSU	16.905,9	19,37
JEOTERMAL	6.127,5	7,02
TOPLAM	87.263,0	100,00

	GWh	%
YENİLENEBİLİR TOPLAM	87.263,0	29,35
TÜRKİYE TOPLAM	297.277,50	100

Şekil 1,2 Tablo 3, 4 Türkiye Elektrik İletim Anonim Şirketi (T.E.İ.A.Ş.) web sitesinden alınmıştır. (T.E.İ.A.Ş, 2017)

1.1.2 Elektrik Enerjisinin İletimi

Ağın ilk kısmı iletim şebekesi olarak adlandırılır, yüksek ve ekstra yüksek voltajda çalışır ve uzun mesafeli iletme adanmıştır. İletim Sistemi Operatörleri (İSO) tarafından yönetilmektedir. Türkiye’de iletim hatlarının işletilmesinden ve bakımından Türkiye Elektrik İletim A.Ş. (TEİAŞ) sorumludur

1.1.3 Elektrik Enerjisi Dağıtımı

Dağıtım şebekesi olarak adlandırılan ağın ikinci kısmı, kısmen yüksek voltajda çalışır, çoğunlukla orta ve düşük voltajlarda çalışır ve bölgesel dağıtımı yapar, daha düşük seviyeli dağıtım sistemlerini besler ve doğrudan müşterilere bağlanır. Bunu, güç şebekesinin kılcal kısım olarak düşünebiliriz. Dağıtım Sistemi Operatörleri (DSO) (BEDAŞ, AYEDAŞ v.b.) tarafından yürütülür.

Hem İSO’lar hem de DSO’lar (Genellikle sistem operatörleri olarak adlandırılırlar), sistemin kendi parçalarının güvenliğini ve güvenilirliğini sağlamak için yasal olarak bağlayıcıdır. Elektrik enerjisinin bir bütün olarak tedarik edilmesi, aktarılması ve kullanılması için kullanılan elektrik bileşenlerinin şebekesine, bir elektrik şebekesi olarak da bilinen bir elektrik güç sistemi (EGS) denir. (G.Gross & Galiana, 1987)

1.1.4 Elektrik Enerjisi Tedarik Zinciri

Tedarik zinciri, hammadde tedarik eden, onları ara mal ve kullanıcıya ulaşacak son ürünlere çeviren ve bu ürünleri müşterilere dağıtan, üretici ve dağıtıcıların oluşturduğu bir ağıdır. (H.L.Lee & Billington, 1992)

Elektrik endüstrisinin kendine özgü özellikleri vardır.

(1) Bölgesel segmentasyon: Elektrik için nakliye kayıpları, daha uzun mesafeler için önemlidir. Elektrik bu nedenle bölgesel bir maldır. Uzun mesafe elektrik nakliyesi ekonomik veya uygulanabilir değildir. Yenilenebilir Enerji Kaynakları’nın bölgesel olarak yatırım miktarı artacağı düşünülmektedir. Ana üretim merkezlerinden (Büyük çaplı santraller, doğalgaz santralleri, nükleer santraller v.b.) lokasyona giderken

oluşan kayıplardan, şebekelerin yatırım ve bakım masraflarından dolayı mikro grid üretim şekli benimseneceği düşünülmektedir.

(2) Enerji ikamesi: Elektrik enerjisinin üretim kaynakları değişkendir ve her üretim metodunun kendi içinde dinamikleri vardır. Nükleer enerji santralleri, hidroelektrik ve benzeri gibi farklı enerji kaynakları, elektriğe dönüştürülebilir. Bu nedenle, elektrik güç tedarik zinciri yönetiminde enerji ikamesi vardır. Ancak enerji üretim kaynaklarının birbirinin yerine kullanılabilmesi mükemmel değildir. Örneğin, doğalgaz santrali gücü istenildiği anda rüzgar enerjisi ile değiştirilemez, çünkü güç şebekesinin sabit bir yüke ihtiyacı vardır, rüzgar enerjisi ise sabit elektrik enerjisi üretemez.

(3) Depolanamaz: Aküler ve depolama güç istasyonu olmasına rağmen, elektrik enerjisinin büyük ölçekli depolanması mümkün değildir. Bu nedenle, elektrik enerjisi üretimi kaynak yönetimi ve güç sisteminin arz ve talep dengesi çok önemlidir.

(4) Sınırlı tekel: Her bir üretim şirketi ayrı bir birey olarak rekabet edebildiği ve yatırımın tekrarlanmadığı için, üretim verimliliğini geliştirmek için gerekli olan teoride üretimde rekabeti sağlamak da mümkündür. Ancak, üretme endüstrisine yönelik yüksek engeller ve iletim kısıtlamaları nedeniyle, mükemmel rekabetçi bir üretim piyasası oluşturmak imkansızdır. (Wang & Gang Cong, 2012)



Şekil 3 Enerji Tedarik Zinciri

Elektrik Enerjisi Tedarik Zinciri Yönetimi (Şekil 3), üretim, iletim, dağıtımdan satışa kadar önemli iş süreçlerinin entegrasyonu olup, arz ve talep arasındaki dengeyi koruyarak müşterilere ve diğer paydaşlara değer katan elektrik ve ilgili hizmetler sunmaktadır.

1.2 Elektrik Sistem Yüğü

Elektrik dağıtımındaki elektrik yükü zamana ve yere göre değişmektedir. Güç üretim ve dağıtım sistemi müşterilerin yük talebine her zaman cevap vermelidir. Bu nedenle, modern elektrik dağıtım hizmetlerinin fiyatlandırma ve tarife planlaması, dağıtım ağı planlaması ve işletimi, güç üretim planlaması, yük yönetimi, müşteri hizmetleri ve faturalandırma için doğru yük verilerine ihtiyaç vardır.

Genelde ihtiyaç duyulan yük bilgisi, bir müşterinin veya bir grup müşterinin, günün farklı saatlerinde, haftanın farklı günlerinde ve yılın mevsimlerinde elektrik enerjisini ve kuruluşun toplam yükünün payının ne olduğunu ve farklı müşterilere ait yüklerin nasıl olduğunu kullanır. (Seppälä, 1996)

Endüstri, elektrik kullanımında önemli bir orana sahip olmasına rağmen, geniş bir yelpazede incelediğimizde elektriğin kullanımında ev içi amaçlar (ışık, ısı, yiyecek hazırlama, elektrikli ev aletlerinin kullanımı vb.), kamu sektörü işletmeleri tarafından sunulan hizmetlerde de (örneğin sokak aydınlatması, demiryolları, vb.) yoğun olarak kullanılmaktadır

Bununla birlikte, bireysel bir yükün (cihaz) veya müşterinin talebi veya kullanım şekli oldukça rastgele ve oldukça belirsizdir. Ayrıca, tipik bir yük dağılımında çok geniş bir bireysel kullanım şekli vardır. Bu faktörler, tahmini bireysel kullanım modellerini tahmin ederek sistem talep seviyelerini tahmin etmeyi imkansız kılar. Ancak, neyse ki, bireysel yüklerin toplamı, istatistiksel olarak tahmin edilebilen ayrı bir tüketim modeli ile sonuçlanmaktadır. (G.Gross & Galiana, 1987)

Elektrik güç hizmetlerinin misyonu, müşterinin elektrik enerjisi ihtiyaçlarını en uygun maliyetle karşılamaktır. Hizmeti karakterize eden en önemli şey, müşterilere

verilen yüküdür. Diğer faktörler güvenilirlik, kesintilerin sayısı ve uzunluğu, gerilimin kalitesi ve tesisatların mekanik ve elektroteknik güvenliğidir.

Ağın iletim kapasitesinin gereklerini tanımlamak, iletim kayıplarını tahmin etmek veya mevcut ağın artan yükleri transfer etme kapasitesini tahmin etmek için yük verileri gereklidir. Yeni üretim kapasitesinin veya enerji alımının planlanması, müşterinin yük varyasyonu hakkında bilgi gerektirir.

1.2.1 Sistem Yüküne Etki Eden Faktörler

1.2.1.1 Takvim Etkileri

Elektrik tüketiminde önemli olan faktörlerden birisi takvim etkisidir. Yaz ve kış mevsimlerinde elektrik kullanımı büyük farklılıklar göstermektedir. Endüstrileşmiş toplumlarda elektrik ısınma amacıyla da kullanılmaktadır. Endüstriyel bölge veya turizm bölgesinin elektrik tüketim karakteristikleri farklıdır. Turizm bölgesi Antalya ve Endüstriyel Bölge İzmit örnek olarak düşünebilir. Bunun dışında günlük ve haftalık elektrik kullanım karakteristikleri mevsimlere göre değişir. Buna örnek olarak festivaller, büyük spor olayları, ya da büyük endüstriyel tesislerin varlığı gösterilebilir. Yaz ve kış mevsimsel yük farklılıkları (gün ışığındaki artış, insan davranışları v.b.), günlük yük farklılıkları (gece ve gündüz arasındaki fark), haftalık döngüler (hafta içi günlerde yük önemli ölçüde yüksektir.) talep miktarını etkiler.

1.2.1.2 Ekonomik Etkiler

Günümüzde elektrik insanların gündelik hayatı için gereklidir. Bu yüzden bir talep olarak ortaya çıkar. Böylece devletin ekonomisi de elektrik kullanımı üzerinde bir etkiye sahiptir.

Örneğin, gelişmiş ülkelerin günlük yük eğrisi azgelişmiş ülkelerin günlük yüklerinin eğrisi ile karşılaştırıldığında farklı modeller göstermektedir. Gelişmiş sanayi için günlük yük eğrisinde 11:00 ile 16:00 arasında büyük sanayi aktivitesi nedeniyle büyük bir zirve gözlemlenirken, az gelişmiş ülkeler için zirve saat 18:00'den sonra yükselmektedir. Bu nedenle, yük tahmini için ülkenin ekonomik durumunu dikkate

almalı ve aynı zamanda uzun vadeli yük tahmini için ülkenin endüstriyel gelişimine bir göz atmalıyız.

Elektrik fiyatları ve insanların satın alma kapasitesi de elektrik kullanımı üzerinde bir etkisi vardır, elektrik pahalı olduğunda daha az tüketiciler tarafından kullanılacaktır. Örneğin, klimayı kullanmak Pakistan'ın nüfusu için uygun değildir. Böylece elektrik fiyatı da günlük yük eğrisini etkiler.

.Dolayısıyla elektrik fiyatı gibi ekonomik faktörler, yük yönetimi ve sanayileşme derecesinin sistem ortalama yükü ve sistemi üzerinde önemli bir etkisi vardır. (Fahad & Arbab, 2014)

1.2.1.3 Meteorolojik Etkiler

Ortalama ve maksimum sıcaklıklar, nem seviyeleri, yağış ve kar, bulut örtüsü; Minimum ve pik sıcaklık, nem, yağmur ve kar yağışı, rüzgar hızı, bulutlu hava yük tahminini etkiler.

Hava faktörü aşağıdakileri içerir. (Fahad & Arbab, 2014)

- ✓ Sıcaklık
- ✓ Nem
- ✓ Yağış
- ✓ Rüzgar hızı ve rüzgar soğutma indeksi
- ✓ Bulut örtüsü ve ışık yoğunluğu

1.2.1.4 Rastgele Olaylar

Spor etkinlikleri, popüler televizyon şovları, başlangıç veya çok fazla güç gerektiren endüstriyel tesislerin kapanış ve açılış işlemleri. (Demir ve çelik fabrikaları gibi, vb.) (Cavallaro, 2005)

1.3 Elektrik Piyasası

Elektrik dünya ekonomisinde en önemli kaynaktır. Ancak, elektrik daha ekonomik ve çevresel olarak temiz olmalıdır. Klasik elektrik şebekesinin çeşitli dezavantajları

vardır: Ulaşımındaki kayıplar, merkezi güç üretimi, büyük üretim tesislerine yüksek bağımlılık, vb. Yeni elektrik şebekesinin amacı, akıllı şebeke, yük eğrisini şekillendirmek ve merkezi olmayan yükleri kullanmak için yükleri yönetmek olmalıdır. Yeni nesil akıllı şebekeler sayesinde, elektrik ağının sağlam, güvenilir, verimli ve dinamik olması sağlanacaktır. Bu yeni kavramlar göz önünde bulundurulduğunda, kamu hizmetlerinin en önemli sorunlarından biri, güç üretimini gerçek zamanlı olarak bir kullanıcı tüketimine ayarlamaktır. Aşırı bir tahmin, bir kaynak israfına yol açarken, düşük bir tahmin, fiyatta ilave talebi karşılayacak bir artış anlamına gelir. Şimdi, daha önce aksine, bu ayar mikro şebekeler gibi daha küçük ortamlarda yapılacaktır. Elektrikli yük tahmini bugün, şebekenin iki tarafını ayarlamak için en iyi yoldur. (Massana, Pous, Burgas, Melendez, & Colomer, 2014)

Şu anda, elektrik iletim ve dağıtım sistemlerinde enerji depolama imkanı yoktur. En iyi güç sistemi çalışması için, elektrik üretimi elektrik yükü talebini takip etmelidir. Üretim, iletim ve dağıtım programları elektrik yükünü tahmin etmek için bazı araçlar gerektirir, böylece elektrik altyapısını verimli, güvenli ve ekonomik olarak kullanabilirler.

Üretim araçları, gelecekteki yük talebini karşılamak için üretim kaynaklarını planlamak üzere elektrik yükü tahmini teknikleri kullanır. İletim araçları, tıkanıklığı ve aşırı yüklenmeleri azaltmak için iletim ağındaki güç akışını optimize etmek amacıyla elektrik yükü tahmini teknikleri kullanır.

Dağıtım araçları, öngörülebilir maksimum yük talepleri ile birlikte, dağıtım sistemleri ağırlıklı olarak merkezden yayılan biçimde olduğu için kısa vadeli elektrik yükü tahminleri fazla önemli değildir. Kısa süreli yüklerin değişiklikleri dağıtım sistemi üzerinde çok az etkisi vardır. (Khatoon, Ibraheem, & Singh, 2014)

1.3.1 Geleneksel Elektrik Piyasası

Geleneksel olarak, elektrik enerjisi tedarik zinciri boyunca tüm faaliyetleri (üretim, iletim, dağıtım ve perakende) kapsayan ve belirli bir coğrafi alanın tüm üreticilerine tedarik sorumluluğu taşıyan devlete ait şirketler tarafından sağlandı. Dikey olarak bütünleşik organizasyonlardı, kendi başlarına özerk olarak hareket ediyorlardı.

Üretiminin bu “geleneksel versiyonları”, kümülatif yükü (şirket seviyesinde) öngörür ve üretim ile tüketim arasındaki sapmaları dengelerlerdi. Bu şirketlerin bir pazar tekeli olduğu için, üretim maliyetlerini düşürmek ya da yenilikçi teknolojileri tanıtmak için motive olmadılar. Tüm masraflar son tüketicinin fiyatına yansıtıldı. Fiyatlar ayrıca, altyapının genişletilmesi ve modernizasyonu için yatırımlar için bir ilaveyi içerecek şekilde yükseltildi ve rekabetçi değildi.

1.3.2 Liberal Elektrik Piyasası

Bir dizi ülke elektrik piyasasında liberalizasyon yoluna gitmeye karar vermiştir. Küçük farklılıklara rağmen, dünya çapındaki elektrik sektörlerinin liberalleşmesi için motivasyon sağlayacak ortak ideolojik ve politik nedenleri vardı. Özellikle, diğer endüstrilerdeki liberalleşmenin başarısının, elektrik sektöründe çoğaltılabileceğine ve geleneksel olarak üretimi, taşımayı ve dağıtımı yöneten dikey olarak bütünleşmiş tekel yapıları parçalamak (veya ayırmak) için ihtiyaç vardı. Daha önce piyasa güçlerince dikey ekonomiye sahip bir tekel olarak görülen bir sektöre rekabetin getirilmesi faydalı olmuştur. Üretim teknolojilerindeki değişiklikler ve iletimdeki gelişmeler nedeniyle tekelleşmede gedik açılması mümkün olmuştur. Elektrik liberalizasyonunun ardındaki motivasyon, uzun vadede, verimlilik artışlarını teşvik etmek, teknik inovasyonu özendirmek ve verimli yatırımlara öncülük etmektir.

Elektrik piyasası liberalizasyonu Şili tarafından öncülük edildi. 1982'de başlayan reform, üretim ve dağıtım şirketlerinin ayrılmasını sağladı, elektrik maliyete dayalı bir formülle fiyatlandırılmıştı. Büyük ölçekli özelleştirme 1986'da başladı ve sektörün (kısmi) dikey ayrışmasına ve toptan elektrik ticaret mekanizmasının oluşturulmasına yol açtı.

Şili'deki reformu, 1990 yılında İngiliz elektrik sektörünün yeniden düzenlenmesi izledi. Toptan satış pazarına 2005 yılına kadar yalnızca İngiltere ve Galler dahildi, ardından İskoçya da dahil oldu..

İskandinav piyasası 1992'de, başlangıçta Norveç'te, daha sonra İsveç, Finlandiya ve Danimarka'da açıldı. Avustralya'da, Victoria ve Yeni Güney Galler pazarları 1994 yılında faaliyete başladı; 1998 yılında Avustralya Ulusal Elektrik Piyasası'nın (NEM)

açılmasını takip etti. Yeni Zelanda, aynı dönemde enerji sektörünü yeniden biçimlendirdi ve 1996 yılında resmi olarak piyasaya çıktı.

Kuzey Amerika'da bir dizi kuzeydoğu pazarı (New England, New York, Pennsylvania–New Jersey–Maryland) 1990'ların sonlarında faaliyete başladı. California 1998'de, üç yıl sonra Teksas ve Kanada takip etti. (R.Weron, 2006)

Liberalleşmiş elektrik pazarlarının sayısı dünya çapında istikrarlı bir şekilde artmaktadır.

Bu nedenle, elektrik liberalizasyonunun ardındaki motivasyon, uzun vadede, verimli yatırımları teşvik etmektir.

1.4 Elektrik Piyasası İşleyişi

Ekonominin çeşitli sektörlerinin serbestleşmesinin başarısını takiben, elektrik piyasaları da benzer bir geçiş sürecine girmiştir. Üretimi, nakli ve elektrik tedarikini yöneten dikey olarak bütünleşik hizmetler, ayrıştırıldı ve üretim ve tedarikte rekabet oluştu.

Dünya çapında elektrik piyasası yapıları ve düzenleyici politikalarındaki farklılıklar göz önüne alındığında, tek bir standart piyasa modeli yoktur. Ancak, dünyanın farklı bölgelerinde uygulanan iki ana pazar organizasyonu vardır, bunlar Perakende Pazarlar ve İkili Sözleşmeler Modeli (Toptan Pazar)'dır. (Barroso, Cavalcanti, Giesbertz, & Purchala, 2005)

1.4.1 Perakende Elektrik Piyasası

Perakende pazarındaki aktörler, yetkili düzenleyici tarafından onaylanmış elektrik sözleşmeleri sunan tedarikçileri ve tedarikçilerini seçme hakkı olan tüketicileri kapsar.

Tedarikçiler üreticilerden elektrik alır ve tüketicilere satar. Tedarikçiler, elektrik enerjisi dağıtımı, iletimi ve dağıtımı için ödenen fiyatın yanı sıra, bazen yenilenebilir enerjilerin üretimini desteklemek, daha savunmasız tüketicileri korumak veya diğer politika hedeflerini desteklemek için kullanılan vergiler ve harçlar için faturalar

gönderir. Tedarikçiler birim fiyatları seçeneklerini elektrik üretim kaynağına ve kullanım saatine göre farklılaştırır.

Endüstriyel tüketiciler için elektrik fiyatları genellikle hane halklarına göre daha düşüktür. Enerji yoğun endüstriler genellikle çok rekabetçi fiyatlardan faydalanır ve ücret ve harçlardan kısmen muaf tutulabilir.

1.4.2 Toptan Elektrik Piyasası

Toptan pazardaki katılımcılar, üreticiler, elektrik tedarikçileri ve büyük endüstriyel tüketicilerdir.

Yukarıda belirtildiği gibi, elektrik, ihtiyaç duyulduğu anda üretilmesi gereken diğer birçok maldan farklıdır, çünkü kolayca depolanamaz. Bu nedenle, elektrik işlemlerinin çoğu, gelecekte bir noktada elektriğin iletilmesini içerir.

Yüklenici pazarının türüne bağlı olarak, işlemler farklı süreleri kapsayabilir:

- 1 Uzun vadeli sözleşmeler: 20 yıl veya daha fazla;
- 2 İleri ve gelecekteki pazarlarda: haftalar öncesinden;
- 3 Gün öncesi piyasasında: ertesi gün;
- 4 Gün içi pazarda: belirli bir süre içinde teslimat (örneğin, bir saat ya da çeyrek saat);

Dengeleme piyasasında: arz ve talebin gerçek zamanlı dengelenmesi.

Elektrik, iki taraf arasında özel olarak işlem görebilir. Aynı zamanda bir enerji değişimi de yapılabilir. Enerji değişiminin fiyatları arz ve talebe bağlı olarak değişmektedir. Toptan satış piyasasında, pik talebi durumunda 80 € / MWh'nin üzerine çıkabilir veya aşırı arz durumlarında sıfıra veya hatta altına düşebilirler. (European Parliament, 2016)

Avrupa Birliği'nde elektrik piyasaları coğrafya, zaman dilimi ve müşteri türüne göre ayrılır.

Avrupa elektrik piyasaları çeşitli seviyelerde faaliyet göstermektedir. Toptan satış pazarları, tüketicilere hitap eden perakende pazarlarından farklı olarak organize edilmektedir. Piyasalar değişiklik gösterebilir

Coğrafi kapsamda, perakende pazarındaki yerel tekliflerden uluslararası toptan satış pazarlarına kadar çeşitlilik göstermektedir. Zaman ölçeklerine göre, toptan piyasalar gerçek zamanlı dengeleme piyasalarından uzun vadeli sözleşmelere kadar uzanır.

Serbest piyasada, iletim sistemi operatörleri ve dağıtım sistemi operatörleri işletiminin yanı sıra elektrik üretmekten de farklı kurumlar sorumludur.

1.4.3 Türkiye Enerji Sektörünün Gelişimi

Elektrik enerjisi Türkiye’de ilk kez 1902 yılında Mersin’in Tarsus ilçesinde bir su değirmeninden yararlanılarak üretilmiştir. Hidroelektrik enerji sayesinde elektrik enerjisiyle tanışmıştır. Kurulu gücü 2 kW olan hidroelektrik santrali günümüzle kıyaslandığında mikro santral boyutundadır. 1914 yılında ilk elektrik üretim tesisi olan Silahtarağa Santrali elektrik üretmeye başlamıştır. Cumhuriyetin ilk yıllarında Türkiye’de iletim sistemi mevcut olmayıp yerel dağıtım sistemleri vardı. 1923 yılında yalnızca İstanbul, Adapazarı, Tarsus elektrikten yararlanabilmekteydi. Kurulu gücümüz 33 MW idi.

Bu dönemden başlamak üzere Türkiye’deki elektrik enerjisinin gelişimi 6 periyotta değerlendirilebilmektedir.

- İmtiyazlar ve dağıtım uygulamalar dönemi (1970'e kadar)
- Bütünleşme (Yarı Tekel) Dönemi (1970-1982)
- Kamu Tekeli Dönemi (1982-1983)
- Özel sektöre açılım dönemi (1984-2001)
- Piyasa Dönemi(2001)
- Serbest (Rekabetçi) Piyasa Dönemi

2017 yılı sonu itibariyle bu kapasite 85.200 MW seviyesine ulaşmış ve 66.453 km iletim hattı, 163.849 MVA trafo gücü ile ülkemiz Avrupa standartlarına sahip bir iletim ağıyla donatılmıştır. (TEİAŞ, 2017)

1980'lere kadar Türkiye Elektrik Kurumu (TEK)'in kontrolü vardı ve Türkiye'de tekel durumdaydı. Devlete ait bir şirketti.

1984 yılında kabul edilen 3096 sayılı yasa ile Türkiye Elektrik Kurumu (TEK) 'in tekel hakkı kaldırılmış, yerli ve yabancı özel sektöre TEK'in dışında elektrik üretim, iletim ve dağıtım tesisleri kurup işletme ve satış hakkı tanınmıştır. Böylece elektrik yatırımlarının gerçekleştirilmesi sürecinde kamunun finansal yükünün azaltılması amaçlanmıştır. Özel sektörün bu yasa çerçevesinde elektrik yatırımlarını gerçekleştirebilmesi için yap-işlet-devret (YİD), yap-işlet (Yİ), işletme hakkı devri (İHD) adıyla anılan finansman modelleri uygulanmıştır. 1990'lı yıllara gelindiğinde, ekonomi alanında uygulanmaya başlanan liberalleşme politikaları elektrik sektörünü de etkisi altına almıştır. Önceki kısımlarda anlatılan elektrik sektöründeki liberalleşme hareketine, 2001 yılında ülkemiz de katılmıştır. Liberalleşmeye geçişle birlikte Türkiye Elektrik Anonim Şirketi (TEAŞ) , üretimde Elektrik Üretim Anonim Şirketi EÜAŞ, iletimde ise Türkiye Elektrik İletim Anonim Şirketi TEİAŞ, satış hizmetlerinde Türkiye Elektrik Ticaret ve Taahhüt Anonim Şirketi (TETAŞ) olmak üzere üçe bölünmüştür.

20 Şubat 2001 tarihinde kabul edilen 4628 Sayılı Elektrik Piyasası Yasası ile elektrik sektöründe piyasa modeline geçilmiştir. Amaçlanan elektriğin yeterli, kaliteli, sürekli, optimum maliyetli ve çevreyle uyumlu bir şekilde son kullanıcıya ulaştırılmasıydı.

1.4.3.1 Türkiye’de Enerji Piyasasının İşleyişi

Enerji Piyasa İşletmecisi (EPIAŞ) ve piyasa oyuncuları elektrik pazarının iki ana unsurudur. Elektrik Pazarı, elektrik santralleri, toptan ve perakende satış firmalarından oluşur. Bunların yanında ikili sözleşmelerin yapılmasına yardımcı olan Takas Bank ve Brokerlar vardır. Elektrik fiziksel olarak son kullanıcıya iletim ve dağıtım hatları üzerinden satılmaktadır.

Elektrik fiyatları her gün bir sonraki gün için, oyuncular tarafından piyasaya ne kadar elektrik satacaklarını veya piyasadan ne kadar elektrik satın alacaklarını, farklı fiyat aralıkları için belirledikleri teklif setleri yardımıyla, saatlik, esnek veya blok bazda teklif setleri ile Gün Öncesi Piyasası’na (GÖP) bildirirler.

Piyasa işletmecisi olan EPIAŞ bu teklifleri kullanarak bir sonraki gün için elektrik talebini tahmin eder ve bu talebi kullanarak bir sonraki günün saatlik elektrik fiyatlarını en küçük olacak şekilde bir arz/talep dengesi kurar. Bu dengeleme işlemi sırasında Sistemin Yönü diye tabir edilen Enerji Açığı / Enerji Fazlası durumu meydana gelir. Sistemdeki yöne bağlı olarak da sistem marjinal fiyatı (SMF) hesaplanır. Sistemde enerji fazlası oluşması durumunda piyasa işletmecisi bu enerji fazlalığından kurtulmak için santrallere YAT talimatları vererek üretimlerini azalttırır. Bu azaltılan üretimler karşılığında santralin ihtiyacı olduğu elektrik sistemdeki enerji fazlalığı ile ucuza karşılanır. Sistemde enerji açığı oluşması durumunda ise piyasa işletmecisi bu açığı kapatmak için santrallere YAL talimatı vererek onları üretmeye teşvik eder. (K.Tınç, 2017)

1.5 Elektrik Yk Tahmin Modelleri

Tahmin

Mevcut verileri ve tahminleri etkileyebilecek gelecekteki herhangi bir olay hakkında bilgi dahil olmak zere mevcut tm bilgileri gz nnde bulundurarak geleceęi olabildięince doęru tahmin etmektir.

Hedefler

Olmak istedięin Őey. Hedefler tahminlere ve planlara baęlı olmalıdır, ancak bu her zaman gerekleŐmez. ok sık olarak, hedefler, bunların nasıl gerekleŐtirileceęine dair herhangi bir plan olmaksızın belirlenir ve gereki olup olmadıklarına dair bir tahmin yapılmaz.

Planlama

Tahminlere ve hedeflere bir cevaptır. Planlama, tahminlerinizi hedeflerinize uydurmak iin gerekli olan uygun eylemleri belirlemeyi ierir.

Tahmin, bir Őirketin birok alanında nemli bir rol oynayabileceęi iin, ynetimin karar alma faaliyetlerinin ayrılmaz bir parası olmalıdır. Modern organizasyonlar, belirli uygulamaya baęlı olarak kısa vadeli, orta vadeli ve uzun vadeli tahminler gerektirir. (Hyndman & Athanasopoulos, Forecasting: Principles and practice, 2013)

Uygun tahmin yntemleri byk lde hangi verilerin mevcut olduęuna baęlıdır.

Kullanılabilir veriler yoksa veya mevcut veriler tahminlerle alakalı deęilse, niteliksel tahmin yntemleri kullanılmalıdır. Bu yntemler tamamen tahminde deęildir - tarihsel verileri kullanmadan iyi tahminler elde etmek iin iyi geliŐtirilmiŐ yapısal yaklaŐımlar vardır.

İki koŐul yerine getirildięinde niceliksel tahmin uygulanabilir:

- GemiŐ hakkında sayısal bilgi mevcutsa;
- GemiŐ kalıpların bazı ynlerinin geleceęe devam edeceęini varsayarsak;

Belirli amaçlar için genellikle belirli disiplinlerde geliştirilen geniş bir tahmin metodu vardır. Her yöntemin kendine özgü özellikleri, doğrulukları ve belirli bir yöntemi seçerken dikkat edilmesi gereken maliyetler vardır.

Çoğu tahmin problemi, zaman serileri verilerini (zaman içinde düzenli aralıklarla toplanır) veya kesitsel verileri (zaman içinde tek bir noktada toplanır) kullanır. (Hyndman & Athanasopoulos, 2013)

1.6 Elektrik Yük Tahmin Kategorileri

Yük tahmini, üç kategoriye ayrılabilir. (Raza & Khosravi, 2015)

1.6.1 Uzun süreli yük tahmini (Long-Term Load Forecasting LTLF)

Uzun vadeli tahminlerin kapsamına bağlı olarak, hükümetlerin ve enerji politikalarının kararlarının yanı sıra elektrik sektöründeki kamu hizmetlerine ve / veya şirketlere yardımcı olabilir. Örneğin, belirli bir imtiyaz alanı için elektrik talebinin tahmin edilmesi, ekipman veya personel için gerekli yatırım miktarını tahmin etmek için kamu hizmeti veya elektrik şirketine destek sağlayacaktır. Ancak, iyi ve tutarlı bir elektrik talebi tahminleri yapmak için, mevcut tüm tahmin teknikleri hakkında genel bir bakış elde etmek, son teknoloji hakkında bilgi sahibi olmak ve ayrıca uzun vadeli talep tahmin tekniklerinin gelişimine genel bir bakış sağlamak önemlidir. Bu bağlamda, uzun vadeli bir elektrik talebi tahmini incelemesinin hazırlanması, paydaşların ve sektörün kurumlarının öngörme tekniklerini daha iyi değerlendirmek ve iyileştirmek isteyebilecekleri büyük bir değere sahiptir. (Estevesa, Bastos, Cyrino, Calili, Souza, & Gheisa, 2015)

1.6.2 Orta vadeli yük tahmini (Mid-Term Load Forecasting-MTLF)

Orta vadeli yük tahmini, bir aydan üç yıla kadar geçen süreye sahiptir, bakım, yakıt rezerv planlama ve birim taahhüdü için önemlidir. (Bunnoon, 2011)

1.6.3 Kısa Vadeli Yük Tahmini (Short Term Load Forecasting- STLF)

Kısa vadeli yük tahmini (STLF), güç sistemi kontrol ve programlamanın ayrılmaz bir parçasıdır. STLF tarafından, genellikle, bir saatten yedi gün öncesine kadar, saatlik, yarım saatlik veya çeyrek saatlik yükleri tahmin edilebilir. STLF, enerji tedarikçileri, sistem operatörleri, finansal kurumlar ve elektrik enerjisi üretimi, iletimi, dağıtımı ve pazarlarındaki diğer katılımcılar için son derece önemlidir. Elektrik şirketleri için elektrik taahhüt üretimi ve iletim planlaması ile ilgili önemli kararlar almak için kesin yük tahminleri gereklidir; ünite taahhüt, üretim sevkiyatı, hidro zamanlama, hidro-termal koordinasyon, rezerv tahsisi ve değişim değerlendirmesi gibi. Yük tahminleri, yük akışı ve beklenmedik durum analizi gibi güç analiz prosedürlerine girdi olarak da kullanılır. Kısa vadeli yük tahminleri, elektrik piyasalarının işleyişi için çok önemlidir, çünkü yük davranışı, elektrik fiyatlarının temel itici gücüdür. Tahmin doğruluğu, enerji şirketlerinin ve diğer piyasa katılımcılarının finansal performansına dönüşür. İyi bir tahminle, 10 GW'lık bir hizmet için tahmin hatalarında % 1'lik bir azalma yıllık 1,6 milyon dolara kadar maliyette azalma sağlar. (Dudek, 2015)

STLF' nin öngörülememesi yetersiz yedek kapasite hazırlığına yol açmakta ve buna karşılık, pahalı pik üniteleri kullanarak işletme maliyetini arttırmaktadır.

Öte yandan, STLF' nin aşırı kestirilmesi, aynı zamanda yüksek işletme maliyeti ile ilgili olan gereksiz büyük yedek kapasite kullanımının önüne geçer.

Tarihi verilerle gelecekteki yükün nasıl tahmin edileceği, özellikle tatillerdeki yük tahmini, aşırı hava koşulları ve diğer anormal günler için önemli bir zorluktur.

1.7 Kısa Vade Yük Tahmin İçin Kullanılan Yöntemler

Genellikle, modeller istatistiksel yöntemlere dayanır ve normal koşullar altında iyi çalışırlar, ancak, yük modellerini etkilediğine inanılan çevresel veya sosyolojik değişkenlerde ani bir değişimin varlığında bazı eksiklikler gösterirler. Ayrıca, bu modeller için kullanılan teknikler çok sayıda karmaşık ilişki kullanır, uzun bir

hesaplama süresi gerektirir ve sayısal kararsızlıklarla sonuçlanabilir. (Patel & Sharma, 2015)

Kısa vadeli yük tahmin için benzer gün yaklaşımı, çeşitli regresyon modelleri, zaman serileri, sinir ağları, uzman sistemler, bulanık mantık ve istatistiksel öğrenme algoritmaları gibi çeşitli yöntemler kullanılmaktadır. Uygun matematiksel araçların geliştirilmesi ve araştırılması daha doğru yük tahmini tekniklerinin geliştirilmesine yol açacaktır.

1.7.1 İstatistiksel Teknikler

İstatistiksel yaklaşımlar, yük ve çeşitli girdi faktörleri arasındaki ilişkiyi veren açık bir matematiksel model gerektirir. Yük tahmini için birkaç klasik model uygulanır: (Srivastava, Pandey, & Singh, 2016)

1.7.1.1 Üstel düzgünleştirme:

Üstel düzeltme, yük tahmini için kullanılan klasik yöntemlerden biridir. Yaklaşım, öncelikle, önceki verilere dayanarak yükü modellemek, sonra gelecekteki yükü tahmin etmek için bu modeli kullanmaktır.

1.7.1.2 Çoklu regresyon yöntemi:

Yük tahmini kullanımı için ağırlıklı en küçük kareler tahmini tekniği kullanılır. Bu analize dayanarak, toplam yük ve hava koşulları ile gün tipi etkiler arasındaki istatistiksel ilişki hesaplanabilir. Bu yöntem durağanlık, eğilim ve mevsimsellik için üç düzgünleştirme sabitine dayanmaktadır.

Örneğin farklı mevsimlerde farklı yükleri etkileyen farklı mevsimsel faktörler dikkate alınmaktadır. Kış mevsiminde, yaz modelinde kullanılan açıklayıcı değişkenlere ek olarak, ortalama rüzgar soğutma faktörü açıklayıcı bir değişken olarak eklenmiştir. İlkbahar ve Güz gibi geçiş dönemlerinde dönüşüm tekniği kullanılır. Son olarak, tatiller için, gerçek tatil yükünü daha iyi tahmin etmek için normal yükten bir tatil etkisi yükü düşülür.

$$Y_t = \alpha_1 y_{t-1} + \alpha_2 y_{t-2} + \beta_1 T_t + \beta_2 T_{t-2} + \dots + \varepsilon \quad 1-1$$

t = Herhangi bir zaman

Y_t = Anlık Veri

β_t = Hesaplanması gereken (Sıcaklık, Nem v.b. gibi) diğer bir serinin katsayıları

α_t = Hesaplanması gereken katsayılar,

ε = Zamana bağlı anlık hata

1.7.1.3 Tekrarlı Yeniden Ağırlıklandırılmış En Küçük Kareler Yöntemi:

Model derecesini ve parametrelerini tanımlar. Yöntem, bir seferde bir değişkeni kontrol eden bir operatör kullanır. Operatör kullanılarak optimal bir başlangıç noktası belirlenir. Bu yöntem, yük dinamiklerinin bir alt-modelini tanımlamak için, otokorelasyon fonksiyonunu ve ortaya çıkan farklı geçmiş, geçmiş yük verilerinin kısmi otokorelasyon fonksiyonunu kullanmaktadır.

$$Y = X\beta + \varepsilon \quad 1-2$$

1.7.1.4 Double Seasonal Holt Winters

Holts ve Winter tarafından ayrı ayrı geliştirilen bu modelin ilki lineer bir trende sahip olan zaman serileri için kullanılan bir yöntemdi. Daha sonra yine aynı kişiler tarafından trend ve tek mevsimselliği olan zaman serileri için geliştirildi. Taylor (Taylor, 2003) 2003 yılındaki çalışmasında çift mevsimselliği, zaman serileri için geliştirmiştir. Norizan Mohamed (A.Jalil, Ahmad, & Mohamed, 2013) 2013 yılındaki çalışmasında Taylor'un geliştirmiş olduğu metotla tüm Malezya'nın yarım saatte bir alınmış verileri incelemiştir. Souza (R.C.Souzo, Barros, & Miranda, 2007)

Güney Brezilya'nın 15 dakikalık elektrik tüketim verilerini exponential smoothing metotla incelemiş, çalışmasında sıcaklık efektini de katmıştır. 2017 yılında Katia Kavanagh (Kavanagh, 2017) yineüstsel düzgünleştirme (exponential smoothing) metotla İrlanda'nın saatlik elektrik tüketimini incelemiştir. Hyndman (Hyndman, Koehler, Ord, & Snyder, 2008) çoklu mevsimsellik metodunu geliştirmiştir. Tezin uygulama kısmında Double Seasonal Holt Winters metodu ayrıntılı olarak anlatılmıştır.

1.7.1.5 Stokastik zaman serileri

Zaman serileri metodu, kullanımının karmaşık olması gibi çeşitli dezavantajlara sahip olmasına rağmen, en popüler yöntem olmuştur. Tahmin etmek için daha fazla zaman ve geçmiş verileri gerektirir. M.Centra (M.Centra, 2011) 2011 yılında İtalyan Demiryolları'nın elektrik tüketim tahminini Arima ve Holt Winters yöntemi kullanarak modellemiştir. Shilpa (G.N.Shilpa & Sheshadri, 2017) 2011 Hindistan Karnataka'da elektrik tüketimini Arima yöntemiyle incelemiştir. Suhartano (Suhartone, 2011) Endonezya'nın elektrik talep tahminini Arima modeliyle R diliyle incelemiştir. S. Singh ve R. Singh (S.Singh & Singh, 2013) Hindistan'ın Pencap Eyaletinde elektrik tüketimini yine Arima modeliyle incelemiştir. 2012 yılında Normah Hassan (S.N.Hassan, Ahmad, Suhartono, & Mohamed, 2012) ve arkadaşları Endonezya'daki elektrik tüketimini Double Sesonal Arima metoduyla modellemiştir.

Zaman serisi kullanımlarının modelleri şunlardır:

- Otoregresif (AR) model
- Hareketli Ortalama Süreci (MA)
- Otoregresif hareketli ortalama (ARMA) modeli
- Otoregresif entegre hareketli ortalama (ARIMA) modeli

Tezin ilerleyen kısımlarında ARIMA modeli ile tahminleme yapılacaktır.

1.7.1.6 Yapay Sinir Ağları

Hesapsal zeka nispeten yeni bir araştırma alanıdır. Hesaplamalı zekanın ifadesi, bulanık mantık, yapay sinir ağları (YSA) v.b'dir. Kısa dönem yük tahmininde en

çok kullanılan modellerden biri yapay sinir ağıdır. Bozkurt, Biricik ve Tayşi (Ö.Bozkurt, Biricik, & Tayşi, 2017) yaptıkları çalışmada Türkiye'nin talep tahminini, Çift Mevsimsel (Double Seasonal) Arima ve Yapay Sinir Ağları ile incelemişlerdir. Yapay Sinir Ağları'nda ileri beslemeli hücre yapısı modelini (feedforward dense) kullanmışlardır. Bu çalışmalarında Türkiye'nin elektrik tüketim miktarını hesaplarken sıcaklığı, nemi, ayrıca tatil günü ve çalışma günü ayrımını Yapay Sinir Ağları ile modellemişlerdir. Çift Mevsimsel (Double Seasonal) Arima ile karşılaştırmışlardır. Pyong ve Huang (P.Kuo & Huang, 2018) 2017 yılında Konvolüsyonel Sinir Ağı (Convolutional NN) ile Amerika Teksas'taki verileri incelemişlerdir. Modelleri üç katmanlıdır. Luis Hernandez (L.Hernandez, et al., 2014) İspanya'da küçük ölçekli yerleşim yerleri için (micro grid) 24 saatlik İleri Beslemeli Hücre (Feedforward Dense) modeli ile tahminle yapmıştır.

1.7.1.7 Uzman Sistemler

Uzman sistemler, son yirmi yılda Yapay Zeka alanında ilerlemenin bir sonucudur. Bunlar, uzmanların deneyimlerine dayanarak kararlar alan kural tabanlı yöntemlerdir. Tahmin yöntemi, alandaki uzman tarafından toplanan bilgilere dayanarak geliştirilmiştir. Veri eksikliğinden dolayı (insan davranışları (festivaller, konserler v.b.) ve/veya hava koşullarında ani değişikliklerden kaynaklanan değişikliklerde tamamlayıcı bir yöntem olarak ele alınmıştır. Bilgi tabanlı uzman sistem, bir uzmanının makine versiyonu olarak görülebilir. Bu olursa bu olur, (IF THEN) kuralları biçiminde yazılan sistemdir.

1.7.1.8 Hibrit Teknikler

Hibrit yaklaşımlar da çok yaygındır. Genel olarak, bu yaklaşımlar, Yapay Sinir Ağları Metoduyla istatistiksel metotlar (Arma, Arima, Exponential Smoothing v.b.) birleştirilmesidir. İstatistiksel metotlarla örneklem dışı (out of sample) bulunan veriler Yapay Sinir Ağları'na örneklem içi (in-sample) olarak verilir. Çıkan sonuç klasik istatistiksel metotlara örneklem içi (in-sample) olarak verilir. Shukur (B.Shukur, Fadhil, Lee, & Ahmed, 2014), Malezya'da değişik karakterli üç yerleşim biriminin elektrik tüketim verilerini Double Seasonal Method ile İleri Beslemeli Hücre yapısı ile hibrit

olarak incelemiştir. Double Seasonal Method'dan çıkan verileri Yapay Sinir Ağ Modelin'de örneklem için kullandıktan sonra çıkan sonuçları tekrar Çift Mevsimsel Metotla (Double Seasonal Method)'da giriş olarak kullanmıştır. Double Seasonal Method ile Hibrit Method'un karşılaştırmasını yapmıştır.



İKİNCİ BÖLÜM

ZAMAN SERİLERİ

Zaman serileri, eşit zaman aralıklarında olduğu gibi, değişken zaman aralıklarında da toplanan iyi tanımlanmış veri ögeleri kümesidir. Zaman serileri analizi, verilerin özelliklerini incelemek için veri setini analiz eden ve karakteristiklere dayanarak dizinin gelecekteki değerlerini tahmin etmede yardımcı olan istatistikte önemli bir yer tutmaktadır. Öngörü, finans, endüstri, tıp vb. alanlarda önemlidir.

Box-Jenkins (Box & Jenkins , 1970) yönteminde üç modelleme söz konusudur. Bunlar otoregresif (AR) süreç, hareketli ortalama (MA) süreci ve hareketli otoregresif (ARMA) süreçleridir. Durağan olmayan bir seri için fark alınması gerektiğinde ARMA süreci, bütünleşik hareketli otoregresif (ARIMA) süreci haline dönüşür.


2.1 Zaman Serilerinde Durağanlık Kavramı

Zaman serilerinden bahsederken karşımıza çıkan tanımların daha iyi öğrenilmesinin iyi bir başlangıç adımı olacağı düşünülmüştür. Aşağıda zaman serilerine ilişkin tanımlar görsel olarak desteklenerek anlatılmıştır.

2.1.1 Durağan ve Durağan Olmayan Seri


1. **Ortalama Durağanlık (Mean Stationary):** Ortalama durağan bir seride verilerin ortalama değerleri sabit bir sayı olduğu ve zamanla değişmediği kabul edilir. Bu zaman serilerinde çok ender olan bir durumdur. Aşağıdaki soldaki betimlemede serinin ortalaması sabit bir sayı etrafında salınım yapmaktadır. Sağdaki betimlemede ise seri zamanla artmakta (trend etkisi ile)

ve bu yüzden seri ortalama olarak zamana bağımlı, diğer bir deyişle ortalama olarak durağan değildir.



Şekil 4 Ortalama Durağanlık


2. **Varyans Durağanlık:** Aşağıdaki betimlemede ise sağ taraftaki kırmızı ile gösterilen zaman serisinde değerlerin yükseklik değiştirerek ortama etrafında zaman değişen bir sapma göstermesi bu serinin varyans durağan olmadığını göstermektedir.



Şekil 5 Varyans Durağanlık

3. **Kovaryans Durağanlık:** Yine kırmızı ile gösterilen betimlemede serinin yaptığı salınımların zamanla sıklaşması yada seyrekleşmesi verilerin birbirleri

ile güçlü bir korelasyon olmasına işaretler ve durağan olmadığını gösterir.



Şekil 6 Kovaryans Durağanlık

2.2 Otoregresif Model AR (p)

Bu modelde anlık değer, önceki değerlerin ve şimdiki değerlerin lineer kombinasyonundan oluştuğunu kabul eder. Bu tarz modeller otoregresif modeller olarak adlandırılır (AR modeller). AR modelleri, geçmiş değerleri kullandığı için tahminleme aşamasında trendi ve mevsimselliği yakalamakta iyidir. Bu nedenle, AR modelleri, bir sonraki tahmin edilen değer, bir önceki zaman döneminin bir fonksiyonu olduğu durumlarda çok yararlıdır.

Otoregresif model, AR (p) olarak tanımlanmıştır, burada p AR bileşeninin derecesini ifade eder. (Pal & Prakash, 2017)

Birinci dereceden AR modeli AR (1) ile gösterilir:

$$y_t = \phi_0 + \phi_1 y_{t-1} + a_t \quad 2-1$$

$\emptyset_0$ = Doğrunun y eksenini kestiği noktadır.

$\emptyset_1$ = -1 ile +1 arasında değer aldığı varsayılan parametredir.

a_t = Varyansı 0 olan, değerleri arasında otokorelasyon olmayan hata serisidir.

Birinci dereceden otogresif süreçte durağanlık sağlanması halinde süreç ortalama etrafında saçılım göstermektedir.

2.3 Hareketli Ortalama Modeli (MA)

Bu modelde anlık değer, önceki hataların ve şimdiki hatanın lineer bir kombinasyonundan oluştuğunu kabul eder.

MA (1) ile gösterilen birinci dereceden hareketli ortalama aşağıdaki gibidir:

$$y_t = \mu + \varepsilon_t + \theta_1 \varepsilon_{t-1} \quad 2-2$$

μ = Doğrunun y eksenini kestiği noktadır.

ε_t = Anlık Error

θ_1 = MA katsayısı (-1 ile +1 arasındadır.)

2.4 Otoregresif Hareketli Ortalama Süreci (ARMA)

$$ARMA(p, q)$$

2-3

$$\left(1 - \sum_{i=1}^p \phi_i B^i\right) y_t = \left(1 - \sum_{i=1}^q \theta_i B^i\right) a_t$$

Seri durağansa, yani kısaca trendden ve mevsimsellikten arındırılmış serilerde kullanılır.

2.5 Box – Jenkins Yaklaşımı (ARIMA)

ARIMA süreçleri, zaman serilerini analiz etmek için kullanılan bir stokastik süreçler sınıfıdır

$ARIMA(p, d, q)$ denklemi aşağıdaki gibi ifade edilir.

$$\left(1 - \sum_{i=1}^p \phi_i B^i\right) (1 - B)^d y_t = \left(1 - \sum_{i=1}^q \theta_i B^i\right) a_t \quad 2-4$$

2-5

$$\phi_p(B) = (1 - \phi_1 B - \dots - \phi_p B^p) = \left(1 - \sum_{i=1}^p \phi_i B^i\right)$$

$$\theta_q(B) = (1 - \theta_1 B - \dots - \theta_q B^q) = \left(1 - \sum_{i=1}^q \theta_i B^i\right) \quad 2-6$$

Buradaki p, d, q deęerleri sırasıyla:

p : Otoregresif kısmını ifade eder. Açık olarak AR(p) derecesidir.

d : Trendi almak için gerekli olan fark integrasyon derecesidir.

q : Moving avarage kısmını ifade eder. Açık olarak MA(q) derecesidir.

y_t ise sadece mevsimsellikten arındırılmış seriyi ifade eder.

Bu denklem sistemine bakıldığında zaman temel olarak bu denklemler serinin şimdiki deęerlerini geęmiş deęerlerin regresyonundan bulur, şimdiki hataları geęmiş hataların regresyonu ile ilişkilendirerek bulur. Bu denklemlerde hesaplanması gereken p, d, q deęerleri ACF ve PACF grafiklerini kullanarak MAPE deęerlerini minimum yapan en küçük dereceler seçilir.

Arima ve Arma arasındaki temel fark integrasyon teriminin $(1 - B)^d$ Arma fonksiyonunda olmamasıdır. Daha açıkça ifade edilmesi gerekirse Arma yönteminde çalışma konusu olan seri mevsimsellikten ve trendden tamamen arındırılmış olmalıdır

2.5.1 ARIMA Modelinin Metodolojisi

1.AŞAMA

TANIMLAMA

1- Veri Hazırlama

Dataların temizlenmesi, aşırı deęerlerin belirlenmesi, eksik dataların tamamlanması

- Datanın deęişken varyans problemi için gerekirse dönüştürülmesi (log, power yada wavelet)
- Datanın duraęan hale getirilmesi ve duraęanlık testleri (Augmented Fuller testi, Ljung-Box testi ve Durbin Watson testi)

2- Model Seçimi

- ACF ve PACF fonksiyonlarının incelenmesi ve uygun model ve derecelerin belirlenmesi

2. AŞAMA

HESAPLAMA VE KONTROL

1- Hesaplama

- Parametrelerin hesaplanması
- Uygun kriterler (minimum AIC, BIC, MAPE) yardımıyla minimum dereceli modelin belirlenmesi..

2- Kontrol

- Hataların (residuals) ACF ve PACF deęerlerinin incelenerek hata serisinde otokorelasyon olmadığının belirlenmesi. AIC ve BIC kriterleri göz önünde bulundurularak derecelerin hesaplanması sonucu hata serisinin otokorelasyonsuz olması garantilenmiş olur. Diğer taraftan MAPE kriter olarak belirlenirse hata serisinin otokorelasyonsuz olması garanti olmaz. Diğer bir deyişle, hata serisinde otokorelasyon olması yüksek ihtimaldir

- Ljung-Box , Augmented Fuller testi ve Durbin Watson testleri

Eğer hatalarda otokorelasyon katsayıları yapılan testlerde sıfıra yakınsa katsayılar ihmal edilir. Bu da her bir zaman aralığındaki hatalar diğer geçmiş hatalarından bağımsızdır.

Eğer otokorelasyon katsayıları üstel olarak bant aralığının içinde bozulmuyorsa seri durağan olarak kabul edilemez, proses birinci aşamadaki model seçimine geri döner.

.

3. AŞAMA

UYGULAMA

Tahminleme

- Model tahminlemede kullanılır. (S.Makridakis, Wheelwrigth, & Hyndman, 1998)

2.5.2 Otokorelasyon fonksiyonu (ACF)

Temel olarak bir zaman serisindeki t anındaki değerler geçmiş değerlerinin ($t-1$, $t-2$, $t-3$ ) ürünüdür.

ACF fonksiyonu (Autocorrelation Function) zaman serisindeki değerlerin geçmiş değerleri (lag) ile olan lineer bağımlılığını göstermektedir. Bu durum lineer regresyon metodunda değişkenlerin birbirleri olan ilişkilerini tanımlayan korelasyon sayılarının zaman serilerine uygulanmış halidir. Zaman serilerinde bu ilişki zaman serisi değerlerinin geçmiş değerlerle olan ilişkisidir ve aşağıdaki denklem ile elde edilir.

$$\rho_s = \frac{Cov(y_t, y_{t-s})}{\sqrt{var(y_t)var(y_{t-s})}} \quad 2-7$$

Zaman serilerinde ise aşağıdaki denklemle ifade edilir.

$$\rho_s = \frac{Cov(y_t, y_{t-s})}{var(y_t)} \quad 2-8$$

Bu denklemi daha açık olarak ifade edersek

$$\rho_s = \frac{\sum_{t=s+1}^T (y_t - \bar{y})(y_{t-s} - \bar{y})}{\sum_{t=1}^T (y_t - \bar{y})^2} \quad 2-9$$

y_t ve y_{t-s} sırasıyla anlık ve s zaman birimi önceki değerini ifade eder. $\bar{y}$ ise serinin ortalamasıdır.

2.5.3 Kısmi Otokorolasyon Fonksiyonu (PACF)

PACF değerleri ise diğer gecikmeli değerlerin (t-1, t-2,...t-k) etkilerinin yok edilmesi ile elde edilir. Kısaca y_t ve y_{t-k} arasındaki ilişkiyi belirler, diğer ara gecikmelerin etkisini ortadan kaldırır. PACF değerleri;

$$y_t = b_0 + b_1 y_{t-1} + b_2 y_{t-2} + \dots + b_k y_{t-k} \quad 2-10$$

Denkleminin sonlu kareler (least square) metoduyla özölmesi ile elde edilen $b_0, b_1, \dots, b_k$ deęerlerdir.

ACF ve PACF deęerleri her zaman $[-1,1]$ aralıęında daęılım gösterir. Bulunan bu deęerlerin istatiksel olarak anlamlı (sıfırdan farklı) olup olmadığı F-test ve t-test hipotez testleriyle anlaşılr. İstatistik olarak sıfırdan farklı olan deęerler daha sonra anlatılacak olan zaman serisi modellerinde dereceleri belirlemek de önemli bir rol oynar. Bu iki fonksiyonda sıfır eksenine göre simetriktir ve duraęan bir seride bu fonksiyonların deęerleri normal daęılım gösterir ve istatiksel olarak anlamsızdır.




2.6 ARIMA Metoduyla Organize Sanayi Bölgesi Verilerinin Tahminlemesi

Bu çalışmada yer alan veriler Türkiye'nin batısında yer alan bir Organize Sanayi Bölgesinin aittir. 2011-01-03 ve 2017-03-28 tarihleri arasındaki saatlik verilerdir.

Zaman serisi çalışmalarında olan genel kurala uyularak 2013 yılı verileri örnek olarak alınmıştır. Verilerin dağılımı Şekil 7'de gösterilmiştir.

Bu zaman aralığındaki mevsimsel davranışı (Günlük mevsimsellik, haftalık mevsimsellik gibi), trendi, süreksizlikleri genel olarak görülmektedir


- 1-Yılbaşı,
- 2-Elektrik kesintisi,
- 3-4 Dini Bayramlar,
- 5- Saat Zaman Dilimi Ayarlanması,
- 6- Resmi Bayram



Şekil 7 İşlenmemiş Veri

Yukarıda belirtilen süreksizlikler Kısa Dönem Yük Tahminin (STFL) yaparken hatalara sebep olduğu için temizlenmesi gerekmektedir.

2. aşama verilerin temizlenmesidir. Yılbaşı ve resmi bayramlarda en yakın tarihli, aynı özelliklerdeki iki günlük verilerle değiştirilmiştir. (Pazartesiye denk geldiyse bir önceki ya da bir sonraki pazartesi aynı saat aralığı gibi.) Meydana gelen elektrik kesintisi ve voltaj dalgalanmalarından meydana gelen düzensizlikler yine en yakın ve aynı özelliklerdeki diğer tarihlerdeki veriler ile değiştirilmiştir. Dini bayramların etkisi daha uzun sürdüğü için veriler ihmal edilmiştir. Saat ayarlamasından dolayı meydana gelen kural dışılıklar o saatin ortalaması alınarak değiştirilmiştir. 2011-2017 tarihleri arasındaki verilerin temizlenmiş hali Şekil 8 de gösterilmiştir.




Şekil 8 Temizlenmiş Veriler

3- Temizlenen veriler daha sonra 10 haftalık periyodlarla çizilmiş, gözle kontrol yapılmıştır. Son olarak verilerin insan hatası etkisini azaltmak için bir bant aralığı tanımlanarak kural dışılıklar (Outlier) belirlenmiştir.


(1) 5 saatlik kayan pencere metoduyla serinin medyanı hesaplanmıştır. L_t^{med} ile gösterilmiştir.

(2) Kural dışılıklar tespit edebilmek için bir bant filtre hazırlanmıştır. Bu bant filtrenin genişliği formülü aşağıda verilmiştir. Kayan pencere içerisindeki 5 saatlik verilerin standart sapması SD olarak gösterilmiştir. Şekil 9’da kırmızılar üst bant sınırını, yeşiller alt bant sınırını, mavilerde gerçek değerlerini göstermektedir. 04.Ocak.2018 ile 16.Ocak.2018 tarihleri arasındaki verilerin incelenmiş hali örnek olarak verilmiştir.

$$B_t = L_t^{med} \pm 5 \cdot SD(L_t - L_t^{med})$$



Şekil 9 Kural Dışılıklar



Şekil 10 Haftanın Günlerine göre elektrik kullanımı

Şekil 10’da görüldüğü üzere pozitif lineer bir trend vardır.

Bu grafikte veriler haftanın günlerine göre gruplandırılarak 24 saatlik ortalama değerleri ile çizilmiştir. Grafikten görüldüğü üzere salı çarşamba perşembe cuma bir grup, pazartesi ve cumartesi bir grup ve pazar günü ise ayrı bir grup oluşturmuştur. Bu grafikte ayrıca kayıp verilerin, süreksizliklerin temizlenmesi sırasında benzer özellikli gün ve saat aralığında seçilmesi gerektiği anlaşılmaktadır.

Yukarıdaki grafiklerden görüldüğü üzere zaman serisi trend ve mevsimsellikten (24 h-168 h) dolayı durağan değildir.

2.6.1 Serilerin Durağanlaştırılması

Elektrik yük zaman serilerinin önemli olan kalıpsal özellikleri aşağıda verilmiştir.

- Yüksek frekanslılık
- Zaman boyunca sabit olmayan ortalama ve standart sapma
- Günlük ve haftalık mevsimsellikler,
- Takvimsel etkiler mevcuttur (hafta sonu etkileri, bayramlar ,resmi tatiller vb...)

- Gün içerisinde belirli saatler arasında enerji tüketiminde önemli değişiklikler vardır.
- Ayrıca çok sık olmasa da çok yüksek ve çok düşük değerler (outliers) mevcuttur.

Zaman serisi modellerinin (AR, MA, ARMA, ARIMA gibi) uygulanabilmesi için serinin trendden ve mevsimsellikten arındırılıp durağanlaştırılması gerekir. Durağanlaştırma da literatürde de en sık kullanılan metot art arda farkların alınmasıdır. Bu çalışmada 168 saatlik (haftalık) ve 24 saatlik (günlük) mevsimsel ve tek gecikmeli (lag) farklar alınarak durağan seri elde edilmiştir. Bu çalışmada söz konusu olan elektrik yük serisi 24 saatlik (günlük) ve 168 saatlik (haftalık) mevsimselliklere sahiptir. Ayrıca düşük eğimlide olsa bir trende sahiptir. Bu sebeple seriyi durağan hale getirmek için aşağıda belirtilen fark işlemleri sırasıyla uygulanmıştır.

Haftalık mevsimselliği yok edebilmek için 168 saatlik gecikmeli fark

$$y'_t = y_t - y_{t-168} \quad 2-11$$

uygulanır.

Daha sonra günlük mevsimselliği yok edebilmek için, bir önceki aşamada elde edilen seriye


$$y''_t = y'_t - y'_{t-24} \quad 2-12$$

farkı uygulanır.

Son olarak trendi almak için son olarak elde edilen seriye tek gecikmeli fark uygulanır.

$$y_t''' = y_t'' - y_{t-1}'' \quad 2-13$$

Yukarıdaki formül tüm veriye uygulanmış, 30.04.2013-25.06.2013 tarihleri arasındaki verilerde örnek olarak aşağıdaki Şekil 9 elde edilmiştir.



Şekil 11 On Haftalık Verilerin trend ve mevsimsellikten arındırılmış hali

Şekil 11’de görüldüğü üzere günlük (24 saatlik) ve haftalık (168 saatlik) mevsimsellik vardır. Şekil 11’de görüldüğü üzere trend ve mevsimsellik (24 h-168 h) çıkarılmış ve geriye rastgele veriler kırmızıyla gösterilmiştir.

Elde edilen serinin durağan olup olmadığı çeşitli testlerle tespit edilir. Ljung-Box testi ve Augmented Fuller testi bu amaçla kullanılan testlerdir. Bu testlerle serinin

ortalama durağanlığı kontrol edilir. Ayrıca Durbin-Watson testi ile trend ve mevsimsellikten arındırılmış serinin otokorelasyonsuz olup olmadığı test edilebilir. Bu metodun yanında ayrıca farkları alınan serinin periodogram grafiği çizdirilerek mevsimsellikten arındırılıp arındırılmadığı ve otokorelasyonlu olup olmadığı kontrol edilebilir. Fakat en sık kullanılan yöntem serinin ACF ve PACF değerleri incelenmesi ve AIC ve BIC değerlerine göre zaman serisi metodlarının derecelendirilmesidir. Bu çalışmada diğer bir kriter olarak literatür de sıkça karşılaşılan MAPE değerini minimum yapan derecelerle regresyona gitme yöntemi kullanılmıştır

Durbin- Watson d İstatistiği

Otokorelasyonu ortaya çıkarmada kullanılan en ünlü iki istatistikçiye aittir.

Testin aşamaları;

1) Hipotez yazılır

$H_0: =0$ $H_A: \neq 0$

2) Anlamlılık seviyesi seçilir.

3) Durbin Watson d istatistiği hesaplanır.

2-14

$$d = \frac{\sum_{t=2}^n (e_t - e_{t-1})^2}{\sum_{t=1}^n e_t^2}$$

Burada e_t , $t=1,2,...,n$ için en küçük kareler regresyonundan elde edilen t'nci kalıntı değerlerini göstermektedir. Eşitlikte hesaplanan d değeri d_L ve d_U şeklinde iki kritik cetvel değeri ile karşılaştırılır.

Bu karşılaştırma sonucunda;

$0 < d < d_L$ ise pozitif otokorelasyon vardır.


$d_L \leq d \leq d_U$ ise karar verilmemektedir.

$d_U < d < 4 - d_U$ ise otokorelasyon yoktur.

$4 - d_U \leq d \leq 4 - d_L$ ise karar verilmemektedir.


$4 - d_L < d < 4$ ise negatif otokorelasyon vardır. (S.Yavuz, 2009)

Bu rastgele veriler ARIMA modelinin giriş verileri olduğu için durağan olup olmaması kritik öneme sahiptir. Durağanlığını araştırırken Augmented Dickey Fuller testi ve Durbin-Watson katsayısı kullanılmıştır. Sonuç olarak İstatiksel test %1 güvenilirlik aralığında, Durbin-Watson katsayısı ise 2,36 yaklaşık değeri bulunmuş, verimiz durağandır.



Şekil 12 Artık Serinin Ortalaması ve Standart Sapması

Şekil 13’de Otokorolasyon Fonksiyonu (ACF) ve Kısmi Otokorolasyon Fonksiyonu (PACF) değerleri verilmiştir. Otokorolasyon ve Kısmi Otokorolasyon katsayıları başlangıçta gecikmeli değerleri negatif olduğu için daha fazla fark alınmasına gerek olmadığı görülmüştür. Ayrıca başlangıçtaki büyük değerlerde üssel olarak sıfıra yakınsadığı görülmektedir. Bu durum serimizin tamamen durağan ve otokorelasyonsuz olduğunu gösterir.



Şekil 13 ACF ve PACF grafiği


2.6.2 ARİMA Modelinin Uygulanması

İki ayrı test aralığında Arima (3,1,4) modeli kullanılarak sonuçlar incelenmiştir.

1. Durum


Başlangıç 2011-01-03 00:00:00 bitiş 2016-02-13 00:00:00 arasındaki datalarla model eğitildi.

Şekil 14’de seçilen tahminleme aralığında gerçek verilerde gözle görülür ani düşmeler gözlenmiştir. Bu yüzden model 2016-02-14 00:00:00 bitiş 2016-02-20 23:00:00 denenmiştir,



Şekil 14 1.Durum için seçilen verilerin 10 haftalık grafiği


Başlangıç 2016-02-14 00:00:00 bitiş 2016-02-20 23:00:00 arasında tahminleme yapıldı. Gerçek verilerle karşılaştırıldı. Hata oranları Ortalama Mutlak Hata Yüzdesi MAPE (Mean Absoulute Percent Error) ile bulundu.



Şekil 15 Ortalama Mutlak Hata Yüzdesi

Şekil 15’de MAPE 4.17 ‘dir. Bu değer 168 saatin ortalama değeridir.

Şekil 16’da da saatlik Ortalama Mutlak Hata Yüzdesi (MAPE) dağılımı göstermektedir.




Şekil 16 Saatlik Ortalama Mutlak Hata Yüzdesi

Şekil 16’da hata oranları hafta sonlarına doğru artmaktadır. Hafta ortası az, hafta başı ve sonuna doğru artmaktadır. Şeki10 ile incelenirse dataların günlere göre gruplama mantığı daha iyi anlaşılabilir.


2. Durum

Başlangıç 2011-01-03 00:00:00 bitiş 2015-06-21 23:00:00 arasındaki datalarla model eğitildi.




Şekil 17 2.Durum için verilen Dataların 8 haftalık grafiği

Şekil 17’de seçilen tahminleme aralığında gerçek verilerde ani düşmelerin olmadığı, rejimin korunduğu iyi haftaya örnek olarak seçilmiştir. Bu yüzden model 2015-06-22 00:00:00 bitiş 2015-06-28 23:00:00 denenmiştir. Gerçek verilerle karşılaştırıldı. Hata oranları MAPE ile bulundu.



Şekil 18 Ortalama Mutlak Hata Yüzdesi

MAPE 2.16’dır. Bu aralıkta MAPE değeri minimuma yakın olduğu düşünülmüştür. Bu değer 168 saatin ortalama değeridir. Şekil 18’de saatlik dağılımı görülmektedir.



Şekil 19 Saatlik Ortalama Mutlak Hata Yüzdesi

Şekil 19’da 120. Saatten itibaren tatil günleri etkisi ve tatil günü hata oranı artmıştır. En zirve noktası ise Pazar günüdür. Hata oranı tatil günleri ve tatil etkisini görüldüğü günlerde daha fazladır.

2. Durum için, 2015-06-22 00:00:00 bitiş 2015-06-28 23:00:00 tarihleri arasında

ARIMA (3,0,3) MAPE 4,7

ARIMA (3,1,5) MAPE 5,2

bulunmuştur.

Model yapısının incelenmesinde, örnek otokorelasyonları ve örnek kısmi otokorelasyonlarına bakılarak model hakkında sezgisel bir karara varılabilir. Fakat bazen bu bakış açısıyla modelin gecikme sayısı hakkında sezgisel de olsa karar verilemeyebilir. Bu durumda bazı model seçim ölçütleri kullanılır. Bunlardan en önemlisi AIC olarak ifade edilen Akaike bilgi ölçütüdür. Akaike bu yöntemi geliştirerek model seçimi için yeni bir yol önermiştir. (Akaike, 1974)

Bu yöntemde farklı sayıda parametreye sahip farklı modeller arasından seçim yapılmaktadır. Yöntem her bir modelin ayrı ayrı en çok olabilirlik fonksiyonunun değeri en büyük olan modeli en uygun model seçmesi olarak özetlenebilir.

ARIMA Modellerin'de Akaike Bilgi Kriteri (AIC) minimum yapan değerler de literatürde tercih edilmektedir. AIC kriteri (p,d,q) değerlerini minimumda tutmaya çalışarak yapar. MAPE ise hata kriterini minimumda tutmaya çalışır.

2.7 Double Seasonal Holt Winters Metoduyla Verilerin İncelenmesi

Bu çalışmada kullanılan metotlardan biride iki mevsimselli Holt-Winters metodudur. Taylor (Taylor, 2003) yaptığı çalışmada daha önce Holt-Winters tarafından geliştirilen tek mevsimsellik ve trend içeren çalışmaları, iki mevsimsellik ve trend içeren zaman serilerine uyarlayarak geliştirmiştir. Taylor bu çalışmasında çarpımsal mevsimsellik kavramını kullanarak aşağıdaki denklemleri geliştirmiştir. Çarpımsal mevsimsellik kısaca şöyle açıklanabilir: zaman serisinde zamanla birlikte ilerlerken mevsimsel salınımların değerleri (yükseklikleri) bir önceki mevsimsel değerlere göre artıyor yada azalıyorsa bu zaman serisi çarpımsal mevsimsellik içerir.

Toplamsal mevsimsellik ise mevsimsel değerlerin zaman boyunca fazlaca etkilenmediği, kabaca sabit kaldığı durumu ifade eder. Hyndman ve Athanasopoulos (2012) toplamsal iki mevsimsellik içeren aşağıdaki denklemi geliştirmiştir.

Çarpımsal mevsimsellikler için denklemler

2-15

$$\hat{x}_t(h) = (S_t + hT_t)D_{t-s_1+h}W_{t-s_2+h}$$

2-16

$$\text{Level:} \quad S_t = \alpha \left(\frac{X_t}{D_{t-s_1} W_{t-s_2}} \right) + (1 - \alpha)(S_{t-1} T_{t-1})$$

2-17

$$\text{Trend:} \quad T_t = \beta(S_t - S_{t-1}) + (1 - \beta)T_{t-1}$$

2-18

$$\text{Seasonality 1 :} \quad D_t = \delta \left(\frac{X_t}{S_t W_{t-s_2}} \right) + (1 - \delta)D_{t-s_1}$$

2-19

$$\text{Seasonality 2 :} \quad W_t = \omega \left(\frac{X_t}{S_t D_{t-s_1}} \right) + (1 - \omega)W_{t-s_2}$$

Toplamsal Mevsimsellikler için denklemler.

2-20

$$\hat{x}_t(h) = S_t + hT_t + D_{t-s_1+h} + W_{t-s_2+h}$$

2-21

$$\text{Level:} \quad S_t = \alpha(X_t - D_{t-s_1} - W_{t-s_2}) + (1 - \alpha)(S_{t-1} + T_{t-1})$$

2-22

$$\text{Trend: } T_t = \beta(S_t - S_{t-1}) + (1 - \beta)T_{t-1}$$

2-23

$$\text{Seasonality 1: } D_t = \delta(X_t - S_t - W_{t-s_2}) + (1 - \delta)D_{t-s_1}$$

2-24

$$\text{Seasonality 2: } W_t = \omega(X_t - S_t - D_{t-s_1}) + (1 - \omega)W_{t-s_2}$$

Tezin konusu olan verilerde günlük ve haftalık mevsimsellikler seri boyunca yaklaşık sabit olduğundan dolayı her iki metot incelenmiştir.

Bu denklemlerdeki α , β , δ , ω katsayılarının ($0 \leq \alpha, \beta, \delta, \omega \leq 1$) aralığında optimize edilmelidir. Optimizasyon konusunda daha ayrıntılı bilgi Hyndman (Hyndman, Koehler, Ord, & Snyder, 2008) kitabında bulunabilir. Bu çalışmada ise belirtilen referansta izlenen ve güvenilirliği yüksek olan MAPE değerini minimum yapan α , β , δ , ω katsayıları dikkate alınmıştır. Bu katsayılar $[0,1]$ aralığında ilk önce 0.1 adım değeri ile döngülere sokulmuş, daha sonra bulunan değerler yeniden daha küçük aralıklarla döngüye sokulmuştur.

İki mevsimsellikli Holt-Winters metodunda önemli diğer konuda mevsimsellikler ve trend için başlangıç değerinin bulunmasıdır. Burada Taylor'un makalesi çerçevesinde aşağıdaki denklemler yardımıyla bu değerler atanmıştır.

2-25

$$L_{S_1+S_2} = \sum_{t=1}^{S_1+S_2} Y_t / (S_1 + S_2)$$


Birinci denklem level için başlangıç değerleridir.

$$b_{S_1+S_2} = \sum_{t=1}^{S_1+S_2} \frac{Y_{S_1+S_2+t} - Y_t}{(S_1 + S_2)} / (S_1 + S_2) \quad 2-26$$


Trend için başlangıç değeri vektörüdür.

Burada dikkat edilmesi gereken önemli konu trend değerinin sabit bir sayı olmasının yanında mevsimsellik ilk değerlerinin vektörel olmasıdır. Günlük mevsimsellik değerleri işlemler sırasında 24 saatte yenilenirken haftalık mevsimsellik 168 saatte yenilenir.

1.Durum tarih aralığı olan 2016-02-14 00:00:00 bitiş 2016-02-20 23:00:00 arasında tahminleme yapıldı. Gerçek verilerle karşılaştırıldı.



Şekil 20 Çarpımsal Çift Mevsimsellikli Holts Winters Ortalama Mutlak Hata Yüzdesi




Şekil 21 Saatlere Göre MAPE dağılımı


Şekil 21’de Çarpımsal Mevsimsellik Metodu (Multiplicative Double Seasonal Exponential Smoothing) haftalık hata oranının en kötü zaman aralığında dağılımı gösterilmiştir.

Aşağıdaki değerlerde minimum Ortalama Mutlak Hata (MAPE) değeri sağlanmıştır.
 $\alpha = 0,001$, $\beta = 0,003$, $\delta = 0,82$, $\omega = 0,993$

Toplamsal Mevsimsellik Metodu (Additive Double Seasonal Exponential Smoothing) ile incelenen veriler aşağıda grafikte gösterilmiştir



Şekil 22 Toplamsal Çift Mevsimsellikli Holts Winters Ortalama Mutlak Hata Yüzdesi



Şekil 23 Saatlere Göre MAPE dağılımı

Aşağıdaki değerlerde minimum MAPE değeri sağlanmıştır.

$$\alpha = 0,015, \quad \beta = 0,00001, \quad \delta = 0,96, \quad \omega = 0,94$$

Bu denklemlerdeki α , β , δ , ω katsayılarının ($0 \leq \alpha, \beta, \delta, \omega \leq 1$) aralığında optimize edilmelidir. Optimizasyon konusunda daha ayrıntılı bilgi Hyndman (Hyndman, Koehler, Ord, & Snyder, 2008) kitabında bulunabilir. Bu çalışmada ise belirtilen referansta izlenen ve güvenilirliği yüksek olan MAPE değerini minimum yapan α , β , δ , ω katsayıları dikkate alınmıştır. Bu katsayılar [0,1] aralığında ilk önce 0.1 adım değeri ile döngülere sokulmuş, daha sonra bulunan değerler yeniden daha küçük aralıklarla döngüye sokulmuştur.

ÜÇÜNCÜ BÖLÜM


YAPAY SİNİR AĞLARI

3.1 Yapay Sinir Ağlarının Gelişimi

Genel olarak yapay sinir ağları insan beyninin biyolojik sinir yapısını taklit ederek sinirsel algılayıcılar yardımı ile önceden öğrenilmiş ya da sınıflandırılmış bilgileri kullanarak yeni bilgiler türetebilen ve oluşturabilen, karar verebilen bilgisayar programlarıdır. (Keskenler & Keskenler, 2017)

İlk yapay sinir ağı modeli Warren McCulloch ve Walter Pitts tarafından 1943 yılında geliştirilmiştir. (McCulloch & Pitts, 1943). Bahsi geçen araştırmacılar, ilk yapay sinir ağı hücresinin yapısını oluşturarak yapay sinir ağlarının temelini attılar. McCulloch ve Pitts, elektrik devrelerini kullanarak insan beyninin hesaplama ve analiz yeteneğinden esinlenerek bu hücreyi geliştirmişlerdir. Bu yapay sinir hücreleri sayesinde her türlü mantıksal ifadenin formülize edilmesinin mümkün olabildiğini gösterdiler. Daha sonra birden fazla hücrenin birlikte çalışması gerekliliğini düşünerek paralel olarak çalıştırma tekniği ile öğrenme kurallarını belirlemeye başladılar.

Yapay Sinir Ağları konusunun işlenmesi sırasında beklide ilk yapılması gereken insan nöronları ile yapay nöronların çalışma prensiplerini açıklamakta fayda vardır. Aşağıda bir insan nöronunun çok basit olarak resmeden ve yapay nöron ile benzerliklerinin sunulduğu bir Şekil 24 vardır.




Şekil 24 İnsan nöronu ile yapay nöronun karşılaştırılması

Şekil 24'te dendritesler çevreden bilgi toplayıp ana yapıya iletir ve ana yapı da bu bilgileri işleyerek veri üretir ve bu verilerde axon lar yardımıyla diğer nöronlara iletilir. Aslında yapay nöronlarda tam bunu taklit etmeye çalışan temel birimlerdir. Yapay Sinir Ağlarının temelini oluşturan hücre (perceptron) olarak adlandırılacak bu basit yapının açıklanması faydalı olacaktır.

Aşağıda biraz daha fazla ayrıntıların verildiği bir diğer Şekil 25 vardır. Burada sağ taraf verilerin (x_1, x_2, x_3 , vb.) girildiği noktalardır. Aynı zamanda bir noktadan da 1 sayısını girilmektedir. Bu sayı bias ilk değeridir. Giriş işleminden sonra bu veriler ilk değerleri rastgele atanan ağırlık oranlarıyla (w_0, w_1, w_2 vb..) çarpılır. Rastgele atanan bu ağırlık katsayıları 0 ve 1 arasında değişir.


Bu noktadan sonra veriler aktivasyon fonksiyonuna girdi olarak kullanılır. Bu noktada aktivasyon fonksiyonunun önemini vurgulamak gerekir. Aktivasyon fonksiyonunun seçimi çözülmek istenen problemin temel yapısı ile doğrudan ilişkilidir. Aktivasyon Fonksiyonu için kullanılan bazı fonksiyonlar ve kullanılan

adım aşağıdaki şekilden görülebilir. Bu aşamada seçilen aktivasyon fonksiyonu yapay sinir ağları ile sınıflandırma, regresyon, non-linear regresyon v.b. problemlerinin çözümünde karar aşaması olan bir aşamadır.



Şekil 25 Basit Yapay Sinir Ağı Hücresi

Bir sonraki adımda aktivasyon fonksiyonundan çıkan veri ve uygun formatta hazırlanan gerçek veriler ile karşılaştırılıp ne yapılacağına karar verilen aşamadır. Aşağıdaki şekilde görüldüğü üzere bir hata (error) geri beslemesi vardır. Bu adımda üretilen veri ve gerçek veri arasındaki hata hesaplanır. Burada hangi hata kriterinin kullanılacağına karar verilmelidir. Ortalama Kareli Hata (MSE), Kök Kareler Karesi (RMSE), Ortalama Mutlak Yüzde Hatası (MAPE) gibi hata bulma yöntemleri kullanılabilir. Hataların bulunmasından sonra bu hataları optimize ederek sonuca yakınsaklaştırma işlemi yapılır. Burada kullanılan hataları optimize etmek terimi hataları minimum yapan değerlere yakınsaklaştırmaktır. Burada hataları minimize etmek için kullanılan çeşitli algoritmalar vardır. Adam, Gradient Descent, Stochastic Gradient Descent, Adamax, Adagrad bunlardan bazılarıdır. Bu algoritmalar belirlenen bir hata oranından sonra durarak optimum veriyi üretir.



Şekil 26 Basit hücre yapısı

3.2 Aktivasyon Fonksiyonlarının Tanıtılması

Bu bölümde günümüz Yapay Sinir Ağları problemlerinde sıkça kullanılan bazı Aktivasyon Fonksiyonlarının anlatılacaktır. Aktivasyon Fonksiyonlarının temel görevi ilgili nöronun aktive edilip edilmeyeceğine karar vermektir. Bu aşama bir karar aşaması olup ilgili nöron, ya yeni bir veri üretecek yada aktive olmadığı için veri üretmeyecektir. (nöron çıkışı sıfır olacak).

Aktivasyon Fonksiyonunun temel görevi problem tanımına göre veriyi dönüştürmektir. Daha açık bir ifade ile bizler sinir ağından lineer olmayan bir problemin regresyonunu çözmesini istiyorsak aktivasyon fonksiyonu lineer olmayan bir fonksiyon olmalıdır.


Aktivasyon fonksiyonu aynı zamanda yapay sinir ağları çalışırken geri besleme sırasında (hataları minimize etme aşaması-back propagation) muhakkak her noktada türevinin sürekli olması gereken bir fonksiyon olmalıdır. Bu teorik kısımları bu tez

konusu dışında olduğu düşünülerek, burada sadece pratik aşamada gerekli olan bilgilerin verilmesiyle yetinilmiştir.

3.2.1 Adım Fonksiyonu (Step-Wise)

$$F(x) = 1 \quad x \geq 0 \quad 3-1$$


$$F(x) = 0 \quad x < 0 \quad 3-2$$



Şekil 27 Adım Fonksiyonu


Bu fonksiyon en basit aktivasyon fonksiyonu olarak kullanılır. Şekil 27’de dikkat edilirse eğer giriş değeri sıfırdan büyükse nöron aktiflenir, eğer değeri sıfır veya küçükse nöron aktiflenmesi olmaz ve sıfır değeri üretir. Bu tip fonksiyon ikili sınıflandırmalarda kullanılır. Sınıflandırmanın iki seçeneğinin matematiksel karşılığı bir veya sıfırdır.

Fonksiyonun türev grafiğine bakıldığında ise x 'in bütün değerleri için türev değeri sıfırdır. Bunun anlamı ise geri besleme sırasında asla hata düzeltme yapılamaz ve geri besleme sağlıklı olmaz.




Şekil 28 Adım Fonksiyonunun Türev Grafiği

3.2.2 Lineer Fonksiyon



Şekil 29 Lineer Fonksiyon

Şekil 29’da ise lineer bir aktivasyon fonksiyonu anlatılmaktadır. Burada girişler belli bir katsayı ile çarpılarak nöronun çıkış değeri belirlenir. Giriş değerleri ve çıkış değerleri sadece bir skala farkı yaratmakta ve bu durum giriş değerlerinin kendi aralarındaki ilişkileri ihmal etmektedir. Bu fonksiyon lineer olmayan problemlerin çözümünde kullanılamaz.



Şekil 30 Lineer Fonksiyon Türevi

Şekil 30’da ise lineer aktivasyon fonksiyonun türev fonksiyonu verilmiştir. Bu fonksiyonun türevi bütün x değerleri boyunca sabit bir katsayıya eşit olup geri beslemede hataları minimize ederken kullanışlı bir fonksiyon değildir. Bütün iterasyonlar boyunca düzeltme miktarının aynı kalması istenilen bir sonuç değildir. Bu yüzden bu fonksiyon lineer olmayan ve çoklu sınıflandırma problemlerinde çıkış nöronu olarak kullanılır. Ağıın üretilen değerini değişiklik yapmadan sonuç iletir.


3.2.3 Sigmoid Fonksiyonu

$$f(x) = 1/(1 + e^{-x}) \quad 3-3$$


Denklemleriyle ifade edilir.

Sigmoid fonksiyonu sürekli ve türevi alınabilir bir fonksiyondur. Doğrusal olmayışı dolayısıyla yapay sinir ağı uygulamalarında en sık kullanılan fonksiyondur. Bu fonksiyon girdi değerlerinin her biri için sıfır ile bir arasında bir değer üretir.

Sigmoid fonksiyonunun matematiksel ifadesi yukarıdadır. Bu fonksiyon 0-1 arasında deęer üretir ve lineer olmayan problemlerde kullanışlıdır.



Şekil 31 Sigmoid Fonksiyonu




Şekil 32 Sigmoid Fonksiyonu Türevi

Türev grafiğinden görüldüğü üzere geri besleme yapılırken iki bölgede farklı davranır. -3 ve 3 arasındaki bölgede küçük değişikliklere büyük tepkiler vererek hata düzeltmelerinde etkili iken belirtilen aralığın dışında türev fonksiyonu sıfıra yakınsadığı için lineerleşmekte ve etkisini kaybetmektedir. Ayrıca bu fonksiyon pozitif değerli girişler için kabul edilebilir sonuçlar üretmekte, negatif değerli giriş verilerinde ise hatalar büyümektedir.

3.2.4 Tanh Fonksiyonu


$$\tanh(x) = \frac{2}{1 + e^{-2x}} - 1 \quad 3-4$$

Denklemleri ile ifade edilir. Grafiği aşağıda verilmiştir.



Şekil 33 Tanh Fonksiyonu

Yukarıdaki fonksiyon ve türev grafiğinden görüldüğü üzere tanh fonksiyonu sigmoid fonksiyonu ile benzer özellikler gösterir. Her iki aktivasyon fonksiyonu da belli aralıklarda türevleri sıfıra yaklaşmakta ve geri besleme sırasında sıfıra yakınsamaktadır. İkisi arasındaki önemli fark ise tanh fonksiyonu -1 ve 1 arasında sigmoid fonksiyonunun aksine simetrik bir yapısı vardır ve böylece -1 ve 1 arasındaki verilerde kullanılabilir.




Şekil 34 Tanh Türev Fonksiyonu

3.2.5 Relu Fonksiyonu


3-5

$$f(x) = \max(0, x)$$

Denklemiyle ifade edilir. Bu aktivasyon fonksiyonu günümüzde en yaygın kullanılan fonksiyonlardan biridir. Lineer olmayan problemlerde bu fonksiyon oldukça başarılı sonuçlar vermektedir. Fonksiyonun kendisi ve türevinin grafiği aşağıda verilmiştir. Bu fonksiyonun sigmoid ve tanh fonksiyonlarına göre daha kullanışlı olmasının sebebi bu fonksiyonun sıfırdan büyük değerler için ürettiği türevi pozitif ve sabitken sıfırdan küçük değerler için ise sıfırdır.



Şekil 35 Relu Fonksiyonu



Şekil 36 Relu Fonksiyonu Türevi

3.2.6 Hata Kriterleri

Aktivasyon fonksiyonunda çıkan verilerin gerçek değerlerle karşılaştırılması gerekmektedir. Bu aşamada lineer ve lineer olmayan sayısal problemlerin hatalarını bulmaya yarayan 4 adet önemli hata kriteri (Loss) vardır. Bu hatalar bulunduğundan sonra ki aşama hataların minimize edilmesidir. Bu sonraki konu başlığında açıklanmıştır.

Ortalama Mutlak Hata (MAE) — Mean Absolute Error (MAE)

MAE, tahmini ile gerçek veri arasındaki farkların mutlak değerlerinin farklarının toplamının ortalamasını ifade eder. Aşağıdaki formülle ifade edilir. Burada:

Y_i = Gerçek Veri

$\hat{Y}_i$ = Hesaplanan veri

n = Toplam veri sayısıdır.

$$MAE = \frac{1}{n} \sum_{t=1}^n |y_i - \hat{y}_i| \quad 3-6$$

Ortalama Kareli Hata (MSE) — Mean Squared Error (MSE)

$$MSE = \frac{1}{n} \sum_{t=1}^n (y_i - \hat{y}_i)^2 \quad 3-7$$

MSE formülünün MAE'den farkı hataların farklarının karelerinin alınmasıyla bulunmasıdır.

Kök Kareler Karesi (RMSE) — Root Mean Squared Error (RMSE)

3-8

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (Y_i - \hat{Y}_i)^2}{n}}$$

Ortalama Mutlak Yüzde Hatası (MAPE) — Mean Absolute Percent Error (MAPE)

3-9

$$MAPE = \frac{1}{n} \sum_{i=1}^n \frac{|Y_i - \hat{Y}_i|}{Y_i}$$

3.2.7 Optimizasyon Algoritmaları

Aktivasyon fonksiyonu sonucu bulunan değerlerin gerçek değerler ile karşılaştırılması gerekmektedir. Daha önce açıklandığı üzere veriler Yapay Sinir Ağı modelinde ilkönce ilk değerleri atanan ağırlık oranlarıyla çarpılıp toplanmakta ve ikinci olarakta yine ilk değerleri atanan bias değerleri ile lineer olarak toplanmaktadır. Daha sonra bu veriler aktivasyon fonksiyonu ile işlem görmekte ve basit hücre işlemi tamamlanmaktadır. Bu durum 2x2 veri vektörü için matris formunda verilmiştir. Bu denklemde aktivasyon fonksiyonu sadece örnekleme amacıyla sigmoid olarak kullanılmıştır. Problemin yapısına bağlı olarak aktivasyon fonksiyonu değişmektedir.

İki Boyutlu Giriş Vektörünün Matematiksel ifadesi aşağıdaki Şekil 37’de verilmiştir.
(N.K.Manaswi, 2018)

$$\begin{bmatrix} X1 \\ X2 \end{bmatrix} \rightarrow \begin{bmatrix} W1 & W2 \\ W3 & W4 \end{bmatrix} \begin{bmatrix} X1 \\ X2 \end{bmatrix} + \begin{bmatrix} b1 \\ b2 \end{bmatrix} \rightarrow \sigma \left(\begin{bmatrix} W1*X1+W2*X2+b1 \\ W3*X1+W4*X2+b2 \end{bmatrix} \right) \quad 3-10$$

Şekil 37 İki Boyutlu Giriş Vektörünün Matematiksel İfadesi

Bu denklemde

X: Giriş verisi vektörü


W: Ağırlık oranları vektörü

b: Bias vektörü

olarak tanımlanmıştır.

Fakat belirtildiği üzere bu işlemlerde kullanılan ağırlık oranı ve bias ilk değerleri çıktı ile gerçek değerler arasında büyük hataların görülmesine sebebiyet vermektedir. Bu hataların azaltılması ve gerçek değerlere yakınsaklaşması için çeşitli optimizasyon yöntemleri kullanılmaktadır.

Hata Optimizasyonunun Gösterimi Şekil 38'dedir. (S.Raschka & Mirjalil, 2017)



Şekil 38 Hata Optimizasyonunun Gösterimi

Yukarıdaki grafik optimizasyon olayının basit bir canlandırmasıdır. Burada dikey eksen $J(w)$ belirlenen hata kriteri iken yatay eksen ağırlık oranlarıdır (w). Temel amaç bu fonksiyonun optimize (minimize) edilmesidir. Her bir iterasyonda (epoch), kullanılan algoritmalar ile minimum hata oranlarına ulaşılmaya çalışılmaktadır.

3.2.7.1 Gradient Descent Algoritması

Bu algoritmada ağırlık oranları her bir iterasyonda yenilenir. Yenilenme miktarı aşağıda verilmiştir.

Aşağıdaki algoritma her bir ağırlık oranı için her katmanda uygulanır.

$$J(w) = \eta \sum_i (y_i - \hat{y}_i)(y_i) \quad 3-11$$

$$\Delta w_j = -\eta \frac{\partial J}{\partial w_j} \quad 3-12$$

$$w = w + \Delta w \quad 3-13$$

η = Öğrenme Katsayısı

Eşitliğin sağ tarafındaki w eski iterasyonun ağırlık oranı iken bulunan Δw ile toplanarak yeni ağırlık oranı elde edilir.

Bu algoritmada bütün veriler için bu işlemler yapıldıktan sonra (her bir iterasyon sonunda) yenileme işlemi yapılmaktadır. Bu algoritma küçük boyutlu veri setleri için geçerlidir. Büyük boyutlu verilerde özellikle mevsimselliğin olduğu verilerde ağırlık matrisinde yüksek otokorelasyonlu ağırlık vektörlerinin oluşmasına sebep olduğu için hatalar meydana getirmektedir. Bu yüzden büyük boyutların incelenmesinde kullanılması tavsiye edilmez.

3.2.7.2 Stochastic Gradient Descent (SGD) Algoritması

Yukarıda bahsedilen Gradient Descent algoritması bütün bir veri seti işleme sokulduktan sonra ağırlık oranlarını yenilemektedir. Stochastic Gradient Descent algoritmasında ise yenileme işlemi belli periyotlarda (batch size) yapılır. Bunun sonucu olarak elde edilen yeni ağırlık oranları bir sonraki veri girişinde ilk değer olarak kullanılarak daha hızlı ve güvenilir sonuçlar elde edilir. Gradient Descent Metod algoritmasında oldukça büyük ağırlık oranları matrisi bir sonraki iterasyon

için depolanırken, bu algoritmada belirlenen periyod miktarının boyutu kadar ağırlık matrisi depolandığı için çok daha hızlı olarak sonuca ulaşır.


3.2.7.3 Adam Algoritması

Bahsedilen algoritmalarda öğrenme katsayısı (η) bütün iterasyonlarda aynı kalmaktadır. Adam algoritmasında ise öğrenme oranı (learning rate) algoritma içinde belirlenen bir fonksiyonla kendi değerini önceki adımlarda belirlenen değerlerini göz önünde bulundurarak kendi belirler. Bu fonksiyon lineer olmayan veri setlerinde belirlenen bir katsayıya bağlı olarak üstel (exponential) bozunma şeklindedir.

Aşağıdaki grafikte sıklıkla kullanılan algoritmaların MNIST veri setinin sınıflandırılmasında karşılaştırılmıştır. MNIST veri seti oldukça popüler bir veri setidir. Değişik insanların 0-9 arasındaki rakamların el yazılarında oluşmaktadır.

Grafikte görüldüğü gibi Adam Algoritması sadece lineer olmayan sayısal verilerin karşılaştırılması haricinde sınıflandırma problemlerinin çözümünde güzel sonuçlar vermektedir.

Adam Algoritması (D.P.Kingma & Ba, 2015)




Şekil 39 Adam algoritması

Şekil 39.'da görüldüğü üzere Adam algoritması kullanılması oldukça başarılı sonuç vermektedir.

3.3 Lstm Blokları (Long-Short-Term Memory)

LSTM (Long Short Term Memory) blokları temel olarak insan beyninden ilham alınarak geliştirilmiştir. Yapay Sinir Ağları (ANN) ve Yapay Zeka AI (Artificial Intelligent) insan beyninin nöronlarının çalışma prensiplerini taklit etmeye çalışır. İnsanlar öğrenirken karar verme aşamasında geçmiş tecrübelerini de (hafıza) kullanırlar. Bu durumu şu an için en iyi şekilde taklit etmeye çalışan yapay nöron modeli olan LSTM modelidir. Bu yüzden LSTM hücresi yada bazen konu içinde LSTM bloğu olarak adlandırılan içsel hafızası olan bu yapay nöronun çalışma prensiplerinden bahsedilmesi yerinde olacaktır. (A.Gulli & Pal, 2017)



Şekil 40 LSTM Bloğu (Long Short Term Memory)

Şekil 40 ilk başta karmaşık olarak gözükebilir ancak adım adım incelendiğinde anlaşılması kolaydır. Bu şekil en temel LSTM hücresidir. LSTM bloğu üç adet giriş vektörü alır.

X_t : o anki değerdir


h_{t-1} : bir önceki bloğun ürettiği (tahminlediği) değerdir.

C_{t-1} : O ana kadar , daha önceki blokların ve zaman adımlarındaki değerlerin ağırlandırılarak oluşturduğu hafıza değeridir.

h_t : bloğun bir sonraki tahminleme işlemine girdi olan, o zaman adımında ürettiği veridir. Burada dikkat edilmesi gereken nokta her bir LSTM bloğunun bir sonraki adım için ürettiği her verinin diğer verilerin işlenmesi sonucu oluşan hafıza bilgileriyle (C_{t-1}) işleme sokulmuş olmasıdır. Kısaca her zaman adımında hafıza yenilenmekte ve her yeni üretilen veri bu hafızanın sağladığı veri ile şekillendirilmektedir. Her adımda anlık veri ile hafıza yenilenmekte ve bir sonraki adım için veri üretilmektedir. Bu hafıza verileri bütün devre boyunca akarak modele katkı sağlamaktadır.

C_t : Yenilenen hafıza çıktısıdır.

Aşağıdaki şekilde seri bağlanmış LSTM blokları görülmektedir. Her bir adımda hafıza yenilenirken her adımda yeni bir veri üretilmektedir. Hafızayı (C_t) birçok giriş ve çıkış bağlantısı olan büyük bir su borusu olarak düşünelim. Her bağlantıyı ise akış miktarını belirleyen vanalar olarak düşünebiliriz. Her bağlantıda ana borudaki su miktarı ve su içeriği değişir. Değişen bu durum bir sonraki çıkış verisini de değiştirir.




Şekil 41 Seri Bağlanmış LSTM Blokları

Burada bağlantılarda sözkonusu olan vanalar ise çarpımsal (forget gate) ve toplamsal vana (merge gate) olarak tanımlanır.

LSTM modeldeki vanalar unutma kapısı (forget gate) temsil eder ve çarpma işlemi yapar. Vana üstündeki çevirme kolunun durumuna göre önceki verilerden gelen ortak hafızanın ne kadarlık bir kısmı yeni verileri etkileyecektir sorusunu


cevaplandırır. Eğer tam olarak açık olursa (elemanları bire yakın olan vektörü ile çarpmak) eski hafızanın katkısı o kadar büyük olur. Eğer kapalı olursa (elemanları sıfıra yakın vektör ile çarpmak) eski hafızanın yeni veri üretimine katkısı o derece az olur. Burada bu vektörleri aktivasyon fonksiyonları belirler

Toplamsal vana (merge vanası) ise yeni üretilen hafıza verisinin geçmiş hafızaya etki ederek yeniler.



Şekil 42 LSTM Çalışma prensibi 1.aşama

İlk aşamada eski hafızanın ne kadar ağırlıklı olarak bundan sonra diğer blokları etkileyeceğini bulunur. Burada bir çarpım işlemi söz konusudur. Elemanlarının bire yakın olduğu bir vektör ile çarpımı eski hafızanın bu aşamada ne kadar etkisini koruyacağını, elemanları sıfıra yakın olan bir çarpımda ise eski hafızanın etkisini yitireceği görülür. Bütün bunlar aktivasyon fonksiyonun üreteceği vektör değerlerine bağlıdır.



Şekil 43 LSTM 2. aşama

LSTM blok içinde bilgi akışını incelemek gerekirse, yukarıdaki resimde görüldüğü üzere bu aşamada dört adet giriş vardır. Bu adımda eski hafızanın kontrolünü yapan yukarıda bahsedilen vektör hesaplanır.


Bu denklemde

h_{t-1} : bir önceki lstm blok çıktısı

X_t : verinin o anki değeri


C_{t-1} : bir önceki bloktan gelen hafıza

B_0 : bias değeri




Şekil 44 LSTM 3. Aşama

Burada ilk toplamsal kapı çarpımsal vananın aldığı verilerin aynısını alırken diğer toplamsal kapı ise anlık değeri bir önceki blok çıktısını alarak iki zaman adımına bağlı olan yeni hafıza verisini elde eder. İlk kapının aktivasyon fonksiyonu sigmoid σ iken diğer kapının aktivasyon fonksiyonu tanh dir.



Şekil 45 LSTM 4. Aşama

Bu aşama LSTM bloklarının en kritik ve de insan nöronlarına en yakın bölümüdür. Bu aşamada eski hafıza ve oluşturulan yeni hafıza toplanarak yeni veri çıkışına hazır hale getirilir.



Şekil 46 LSTM 5. Aşama

Artık LSTM bloğumuz yeni hafızanın ve yenilenen eski hafızanın ve anlık verinin etkisi ile yeni veri çıkışı üretecek hale gelmiştir.


LSTM’de 168 saatlik sağlıklı bir tahminleme yapmak istediğimiz zaman en az 336 saatlik veri girişi gereklidir. Bu LSTM’nin çalışma sınırlarının dışındadır. Bu yüzden Kısa Dönem Yük Tahminleri’nde 24 saatlik tahminleme yapılmak istenirse LSTM kullanılabilir.

Bu çalışmada veriler İleri Beslemeli Yapay Sinir Ağları (Feedforward ANN) ve Convolution ANN kullanılarak Hibrid bir model oluşturulmuştur.


3.4 İleri Beslemeli Sinir Ağı (Feedforward ANN)

Bu tip sinir ağları daha önce anlatılan temel nöronların (perceptron) seri şekilde bağlanmasıyla oluşturulan bir yapıdır. Her bir katman (layer) içindeki nöronlar bir sonraki nöronların her birine ağırlık oranlarıyla bilgi iletir ve bilgi akışı girişten

çıkışa doğrudur. Aynı katmandaki nöronların birbirleriyle bağlantıları yoktur. Genel olarak bir veya iki gizli katman sıkça kullanılmaktadır. İki'den fazla gizli katman olan yapılar literatürde derin öğrenme (deep learning) olarak adlandırılır. Her bir katmandaki nöronlar aynı aktivasyon fonksiyonuna sahipken değişik katmanların aktivasyon fonksiyonları farklı olabilir. Giriş katmandaki nöronlar lineer aktivasyon fonksiyonuna sahiptir. Bu durum sıklıkla çıkış nöronu içinde geçerlidir. Fakat problemin yapısına bağlı olarak gizli katmandaki ve çıkış katmandaki aktivasyonlar değişir. Aşağıda ki grafiklerde çeşitli derin öğrenme yapıları görülmektedir. Bu yapılarda katman sayısı ve bu katmandaki nöron sayıları değişkenlik gösterebilir.



Şekil 47 Üç Gizli Katmanlı İleri Beslemeli Sinir Ağı Örnek 1




Şekil 48 Üç Gizli Katmanlı İleri Beslemeli Sinir Ağı Örnek 2

Derin öğrenmedeki (ikiden fazla gizli katmanı olan yapılar) temel problem geri besleme sırasında ortaya çıkmaktadır. Genel olarak optimizasyon algoritmalarına bağlı olarak türevin sıfıra yaklaşması (gradient vanishing) veya aşırı derecede büyümesi (gradient explosion) problemleri görülmektedir. Bu yüzden zaman serilerinin tahminlemesi amacı ile kullanılmak istendiğinde yapının ikiden fazla gizli katman içermesi problemlere sebep olur.

LSTM ve İleri Beslemeli yapıların yanında CNN modellerde lineer olmaya problemlerin çözümünde düşük hata oranları vermesi sebebiyle kullanılmaktadır. Günümüzde oldukça popüler hale gelen CNN model konuşma tanınması, resim tanınması gibi temel işlevler amacıyla geliştirilmiş olmasına karşın art arda gelen (zaman serisi gibi) verilerin tahminlemesi içinde uygun bir yapı oluşturmuştur.

3.5 Konvolüsyonel Sinir Ağı (Convolutional Neural Network)

Aşağıdaki Şekil 49’da derin Konvolüsyonel Sinir Ağı (CNN) yapısı gösterilmiştir.



Şekil 49 Konvolüsyonel Sinir Ağı (CNN)

Şekil 49’dan anlaşılacağı üzere modelde temel olarak iki ana unsur vardır. Birinci yapı benzerliklerin tanındığı (seri değerlerinin birbirleri ile ilişkilendirildiği) bileşenlerin ayrıştırılması bölümü (Feature Extraction) ve daha sonra tahminlemenin (Forecasting) yapıldığı İleri Besleme Hücre (Feedforward Dense) bölümü vardır.

Çalışılan modelde Conv1D ve İleri Beslemeli Hücre Yapısı’nda Relu Aktivasyon Fonksiyonu kullanılmıştır.

Conv1D katmanında veriler belirlenen ağırlık matrisi (kernel) ile çarpılır ve daha sonra belirlenen filtreler ile veriler arasındaki ilişkiler belirlenir. Havuzlama (Pooling) bölümünde bu verilerin boyutları düzenlenir. Daha sonra değişik filtreler uygulanarak elde edilen veriler Düzleştirme (Flatten) katmanına gönderilir. Burada daha sonra gelen tahminleme bölümü için her filtre için elde edilen veriler artarda eklenir. Veri artık tahminleme için hazırlanmıştır. (Kuo & Huang, 2018)

Bu çalışmada tek katmanlı bir yapı oluşturulmuş ve oluşturulan model için etkili faktörler uygulama bölümünde anlatılmıştır.

3.6 Organize Sanayi Verilerinin Yapay Sinir Ağları Modeliyle İncelenmesi

Zaman serilerinin tahminleme çalışmalarının yapay sinir ağları ile uygulamaları günümüzde oldukça yaygın hale gelmiştir. ANN modellerinde veriler durağan hale getirilmeden de (mevsimsellik ve trendin alınmadan) sonuca gidebilmektedir. Bu bölümde çalışma konusu olan veriler hibrid bir modelle incelenmiştir.

Yapılan çalışmada Python programlama dili, yapay sinir ağları kütüphanesi Keras, Numpy, Pandas, Sci-Kit ve Statsmodels ve bazı başka hazır kütüphaneler kullanılmıştır. Hazırlık aşamalarında R programlama dili ve bu dile uygun bazı kütüphanelerden de faydalanılmıştır. Bütün bu programlama dilleri ve kütüphaneleri ücretsizdir. Daha fazla bilgi için bu dillerin resmi web siteleri ziyaret edilebilir.

Yapay sinir ağları incelemesinin sonuçlarını vermeden önce kısaca etkili parametreler hakkında bilgi vermek faydalı olacaktır.

n_input: Bu çalışmada gecikmeli değerlerin sayısını vermektedir. Tahmin yaparken kaç gecikmeli değerin hesaplanmak istenen değere etkisi vardır sorusunun cevabıdır. Bu değerler hesaplanırken ACF (Autocorrelation Function) ve PACF (Partial Autocorrelation Function) yararlanılması gerekir. Bu fonksiyonlarda elde edilen katsayıların istatistiksel anlamlılıkları göz önünde bulundurulmalıdır. Bu gecikmeli değerler sıralı olabileceği gibi (Standart Arima modellemesinde olduğu gibi) istenilen gecikmeli değerler de kullanılabilir. Bu çalışmada 672 ve 1344 sıralı gecikmeli değerler baz alınmıştır. Bu iki değer 4 haftalık ve 8 haftalık periyodları kapsamaktadır. Böylece trend ve mevsimselliği bağlı olan diğer dışsal etkileride (sıcaklık, nem v.b.) göz önünde bulundurabilir.

n_step: Tahmin edilecek adım sayısıdır. Bu çalışmada 168 saatlik bir zaman dilimi (bir haftalık) tahminlemek istenmiştir. Hali hazırda eldeki verilerin 24 saatlik ve 168

saatlik iki mevsimselliğe sahip olduğu düşünülürse bu değer makuldür. Yapay Sinir Ağları modellerine veri hazırlama aşamasında bu değer önemlidir.

epochs: ANN modellemelerinde bütün veri üzerinde yapılan iterasyon sayısıdır. ANN modellerinde rastgele olarak atanan ağırlıklar (weights) sonucu bulunan değerler ile gerçek değerler, uygun bir hata metodu (MSE (mean squared error gibi)) ile karşılaştırılarak hata değerleri her bir iterasyonda minimize edilir. Her iterasyonda bütün veriler üzerinde işlem yapılır ve bu değerler hataları minimize etmek için yenilenir.


batch_size: Herbir iterasyon sırasında hataları minimize etmek için işlem yapılırken hangi sıklıkla veriler yenilenir, sorusunun cevabını vermek gerekir. Bu batch_size ile belirlenir. Yukarıda anlatılanların ışığında her iterasyonda (epochs) veriler belirlenen değer periyodunda (batch_size) 1 kere yenilenir. Bu çalışmada verilerin 168 saatlik mevsimselliği göz önüne alınarak batch_size değeri 168 olarak alınmıştır.

Yapay Sinir Ağı Modelinde aşağıdaki tarihler arasındaki veriler incelenmiştir.

Başlangıç 2011-01-03 00:00:00 bitiş 2016-02-13 00:00:00 arasındaki datalarla model eğitildi. Eğitim ve doğrulama verilerinin oranı 0,2 olarak seçilmiştir.

Başlangıç 2016-02-14 00:00:00 bitiş 2016-02-20 23:00:00 arasında tahminleme yapıldı. Gerçek verilerle karşılaştırıldı. Hata oranları MAPE ile bulundu. Bu çalışmada giriş verisinin boyutu (n_input) 672 geçmiş veri, batch_size 168, iterasyon sayısı (epochs) 150 seçilmiştir. MAPE değeri 4,17 bulunmuştur.

Şekil 50’de kırmızılar gerçek değerleri, maviler tahminlenen değerleri göstermektedir.



Şekil 50 Yapay Sinir Ağları Modeli

Giriş verisinin boyutu (n_input) 672 geçmiş veri, batch_size 168, iterasyon sayısı (epochs) 200 seçildiğinde MAPE değeri 4,503 bulunmuştur.

Giriş verisinin boyutu (n_input) 1344 geçmiş veri, batch_size 168, iterasyon sayısı (epochs) 100 seçildiğinde MAPE değeri 7,529 bulunmuştur.

Yapay Sinir Ağları modeli (Şekil 50) ile ARIMA (3,1,4) modelinde MAPE değeri 4,17 olarak aynı çıkmıştır.

Double Seasonal Exponential Metodu’nda, Çarpımsal Mevsimsellik Metodu’nda MAPE değeri 4,35, Toplamsal Mevsimsellik Metodu’nda MAPE değeri 4,36 çıkmıştır.

Tatil etkisi pazartesi, cumartesi ve pazar günlerinde güçlü bir şekilde gözlemlenmektedir. Organize Sanayi sitesinde elektrik kullanımı, ani haftalık yükselmelere ve alçalmalar gözlemlenmiştir. Organize sanayi içindeki işletmelerin büyüklükleri, sipariş durumları, cihaz arızaları, elektrik kesintileri, mesai v.b. durumların bu dalgalanmalara etkisinin büyük olduğu düşünülmektedir. Bu da tahminlemeyi zorlaştırmaktadır.

SONUÇ VE ÖNERİLER

Elektrik piyasasında arzın doğru yapılabilmesi ve kaynakların verimli kullanılabilmesi için talebin yüksek doğruluk oranında yapılması gerekmektedir.

Kısa Dönem Yük Tahminleri (STLF) bir saatten bir hafta öncesine kadar kontrol, güç güvenliği, piyasa operasyonu ve akıllı şebekeler için makul sevkiyat planlarının planlanmasında önemli bir rol oynamaktadır. Bununla birlikte, yüke çeşitli özelliklerin karmaşık etkileri nedeniyle yüksek doğruluk elde etmek zordur. Verilerini incelediğimiz Organize Sanayi Bölgesi'nde bu etkiler şunlardır. Yeni sipariş, mesailer, kapasite artışı ya da tam aksine, sipariş iptalleri, fabrikanın üretime ara vermesi gibi etkiler. Değerlerin sağlıklı bir şekilde tahmin edilmesi için verilerin iyi analiz edilip en uygun istatistiksel metotla çözülmesi gerekmektedir.

Organize Sanayi'nin hangi istatistiksel modeli tercih ederse işletmeye daha fazla fayda sağlar sorusunun cevabı aranmıştır. Araştırma yapılırken yöntemler birbirleriyle tutarlı sonuçlar üretmiştir. Tatiller içinde uygun modeller aranması işletmelere kar getirebileceği düşünülmektedir. Hava koşullarının etkisi genelde kısa dönemde etkili olmadığı düşünülmektedir. (Taylor, 2003)

Üç İstatistiksel metotla veriler incelenmiştir, Ortalama Hata Yüzdeleri birbirleriyle kıyaslanmış, Organize Sanayi Bölgesi için en doğru tahminlemeyi yapan model oluşturulmaya çalışılmıştır.

Tablo 5 Sonuçlar

	MAPE
Yapay Sinir Ağı	4,17
ARIMA (3,1,4)	4,17
Double Seasonal Exponential Metodu	
Toplamsal	4,36
Çarpımsal	4,35

Birinci bölümde elektriğin tanımı, üretimi, iletimi ve dağıtımı konusu anlatılmıştır. Elektrik piyasasının tekel piyasadan liberal piyasaya geçiş süreci açıklanmıştır. Elektrik tahmin yöntemleri üç kategoriye ayrılmıştır. Bunlar kısa süreli elektrik talep tahmini, orta vade elektrik talep tahmini ve uzun vade elektrik talep tahminidir.

Çalışmanın ikinci bölümünde elektrik talep tahminlerinde kullanılan zaman serileri açıklanmıştır. Bu çalışmadaki veriler Kısa Dönem Yük Tahminin’de kullanılan yöntemlerden olan Arima Modellemesi, Double Seasonel Exponatial Smoothing Metod ve Yapay Sinir Ağları metoduyla incelenmiştir. Elektrik tüketimin miktarının ani bir şekilde değiştiği hafta incelenmiştir.

Organize Sanayi Bölgesi’nde kullanılan 2011-2017 yılları arasındaki saatlik elektrik kullanım verileri Arima metoduyla haftalık olarak (168 saatlik) tahminlemesi yapılmıştır. İncelenen veriler de en iyi Ortalama Hata Yüzdesi (MAPE) Arima (3,1,4) modelinde 4,17 olarak bulunmuştur.

Organize Sanayi Bölgesi’nde kullanılan 2011-2017 yılları arasındaki saatlik elektrik kullanım verileri Double Seasonal Holt Winters metoduyla incelenirken iki metod kullanılmıştır. Bir tanesi Toplamsal Double Seasonal Holt Winters metodu, diğeri ise Çarpımsal Holt Winters Metodu’dur. 168 saatlik verilerin tahminlemesinde Toplamsal Holt Winters Metodu’nda Ortalama Hata Yüzdesi MAPE 4,36, Çarpımsal Holt Winters Metodu’nda ise 4,35 bulunmuştur.

Arima (3,1,4) Modelinin Holt Winters metodundan daha iyi sonuç verdiği gözlemlenmiştir.

Çalışmanın üçüncü bölümünde Yapay Sinir Ağları açıklanmıştır. Yapay Sinir Ağları’nın gelişimi anlatılmış, aktivasyon fonksiyonları açıklanmıştır. Uzun Kısa Dönem Hafıza Metodu (LSTM), İleri Beslemeli Sinir Ağı (Feedforward ANN), Konvolüsyonel Sinir Ağları (Convolutional Neural Network) anlatılmıştır. Organize Sanayi Bölgesi’nin 2011-2017 arasındaki elektrik kullanımı saatlik verileri

Konvolüsyonel Sinir Ağları metoduyla incelenmiştir. 168 saatlik haftalık verilerin Yapay Sinir Ağları Modeli'ndeki Ortalama Hata Yüzdesi (MAPE) 4,17 çıkmıştır.

Arima (3,1,4) ile Yapay Sinir Ağları Modeli Ortalama Hata Yüzdeleri birbirine eşit çıkmıştır. İki yöntemde tahminlemede tercih edilebilir. Her bir veri setinde model parametrelerinin optimizasyonu gerekir. (YSA Grid Search)

Elektrik enerjisinin tahminlemesi sadece tüketici açısından önemli olduğu kadar, üretici açısından da önemlidir. Bu çalışmada kullanılan İstatiksel Yöntemler özellikle üretimi değişken olan yenilenebilir enerji kaynaklarının (Rüzgar, güneş v.b.) üretim tahminlemesinde de kullanılabilir. Aynı zamanda da elektrik fiyat analizlerinde de tüketim tahmini en önemli temel girdidir.

İşletmelerin enerji giderlerini düşürmenin yolu sadece gereksiz tüketimin önüne geçmek, tasarruf tedbirleri almak değildir. Dünya enerji piyasaları artık liberalleşmekte ve tekel piyasalardan serbest piyasalara geçilmektedir. Enerji fiyatları ve bu fiyatların uygulandığı tarifeler saatlik – günlük değişmektedir. Uzun dönem ya da sabit fiyat garantili antlaşmalar geçerliliğini yitirmektedir. Yarın ya da gelecek hafta ne kadar tüketim yapacağımız sorusuna cevap veremediğiniz sürece daha az elektrik kullansanız dahi daha fazla ödeyebilirsiniz.

Hataların en yüksek olduğu zaman aralığı sabah 10.00 ile öğlen 14.00 arasındadır. Bu zaman dilimindeki hataları azaltacak matematik modellemeler üzerine çalışmaların yapılması faydalı olacağı düşünülmektedir.

KAYNAKÇA

- Akaike, H. : “A New Look at the Statistical Model Identification”, **I.E.E.E, Transactions on Automatic Control**, AC-19, 1974, s. 716-722.
- Barroso;
Cavalcanti, T., H.;
Giesbertz, P.;
Purchala, K.: “Classification of Electricity Market Models Worldwide”, **International Symposium CIGRE/IEEE PES**, 2005 , s.102.
- Bozkurt, Ö.;
Biricik, G.;
Tayşi, C. : “Artificial neural network and SARIMA based models for power load forecasting in Turkish electricity market”, **Plos One**, (Nis. 2017), s.1-24.
- Box, G.;
Jenkins , G. : **Time series analysis, forecasting and control**, Holden-Day, 1970.
- Bunnoon, P. : “Mid-Term Load Forecasting Based on Neural Network”, **International Journal of Computer and Electrical Engineering**, Vol. 3, No. 4, 2011, s.600-605.
- Cavallaro, F. : “Electric load analysis using an artificial neural network”, **International Journal of Energy Research**, 2005, s. 377-392.

- Centra, M. : “Hourly Electricity Load Forecasting :An Empirical Application to the Italian Railways”, **World Academy of Science, Engineering and Technology International Journal of Energy and Power Engineering**, Vol:5, No:8, 2011, s.1026-1032.
- Dudek, G. : “Pattern similarity-based methods for short-term load forecasting Part 1:Principles”, **Applied Soft Computing**, 2015, s.277-287.
- Estevesa, T.;
Bastos, B.; Cyrino,
F.; Calili, R.;
Souza, R.: “Long Term Electricity Forecast: A Systematic Review” **I. Information Technology and Quantitative Management**, Procedia Computer Science 55 , 2015, s. 549 – 558
- Fahad, M., U.;
Arbab, N. : “Factor Affecting Short Term Load Forecasting”, **Journal of Clean Energy Technologies** , Vol.2, No.4., 2014.
- Gross, G.;
Galiana, F. : ”Short Term Load Forecasting”, **IEEE**, vol.75, 1987, s.1558-1573.
- Gulli, A.; Pal, S. : **Deep Learning with Keras**, Packt Publishing , 2017, s. 186-191.
- Hassan, S. N.;
Ahmad, M.;
Suhartono;
Mohamed, N. : “A Comparison of the Forecast Performance of Double Seasonal Arima and Double Seasonal Arfima Models of Electricity Load Demand”, **Applied Mathematical Sciences**, Vol.6, No.135, 2012, s.6705-6712.

- Hernandez, L.;
Baladron, C.;
Aguiar, M.;
Calavi, L.;
Carro, B.;
Esguevillas, A. :
“Artificial Neural Network for Short-Term Load Forecasting in Distribution Systems”, **Energies**, 2014, s.1576-1598.
- Hyndman, R.;
Athanasopoulos, G: **Forecasting: Principles and practice** , Monash University , Australia, 2013.
- Hyndman, R.;
Koehler, A.;
Ord, J.;
Snyder, R. : **Forecasting with Exponential Smoothing**, Springer Science & Business Media., Germany, 2018.
- Jalil, A.;
Ahmad, H.;
Mohamed N.:
“Electricity Load Demand Forecasting Using Exponential Smoothing Methods”, **World Applied Sciences Journal** 22, s.1540-1543.
- Kavanagh, K. :
“Short Term Demand Forecasting for the Integrated Electricity Market”, **Student Journal of Energy Research**, 2017, Article 1.
- Keskenler, M.;
Keskenler, E. :
“Geçmişten Günümüze Yapay Sinir Ağları ve Tarihçesi”, **Takvim-i Vekayi**, 5(2), 2017, s.8-18.

Khatoon S.;
Ibraheem ;
Singh, A.;
Priti. :
“Effects of Varios Factors on electric Load Forecasting : An Overview” , **6th IEEE Power India International Conference**, 2014.

Kingma,D.,P.;
Jimmy Ba;
Adam A.:
“A Method For Stochastic Optimization”, **Published as a conference paper at ICLR** , 2015.

Kuo, P.-H.;
Huang, C. :
“A High Precision Artificial Neural Networks Model for Short-Term Energy Load Forecasting”, **Energies**, MDPI, (Ocak 2018), s. 1-13.

Koç, E.;
Şenel, M., C.:
“Dünyada ve Türkiye’de Enerji Durumu - Genel Değerlendirme”, **Mühendis ve Makine Dergisi**, 54 / 639, 2013, s. 32-44.

Lee, H., L.;
Billington, C. :
“Managing supply chain inventory: pitfalls and opportunities” , **Sloan eManagement Review**, Vol.33, No.3, 1992, s.65-73.

Manaswi, N., K.:
Deep Learning with Applications Using Python , Apress
Springer Science, Business Media New York, 2018, s.50.

Makridakis, S.;
Wheelwrigth C.;
Hyndman J.:
“Forecasting Methods and Aplications” , **Journal of the American Statistical Association**, Vol. 94, No. 445 (Mar. 1999), s. 345-346.

Massana, J.;
Pous, C.;
Burgas, L.;
Melendez, J.;
Colomer, J. :
“ Short-term load forecasting in a non-residential building
contrasting models and attributes”, **Energy and Buildings**, (Ekim.
2014), s.322-330.

McCulloch, W., S.;
Pitts, W. :
“A logical calculus of the ideas immanent in nervous activity”,
Buttetin of Mathematics and Biophysics, Volume 5, Issue 4,
1943, s.115-133.

Pal, A.;
Prakash, P. :
Practical Time Series Analysis, PACKT Books - Packt
Publishing, 2017, s.154.

Patel, S.;
Sharma, S. :
“A Review of very Short-Term Load Forecasting (STLF) using
Wavelet” , **International Journal of Science**, Engineering and
Technology Research (IJSETR) Volume 4, Issue 12. (Ara. 2015).

Raschka, S.;
Mirjalil, V. :
Python Machine Learning , Packt Publishing, 2017

Raza, M., Q.;
Khosravi, A.:
“A review on artificial intelligence based load demand forecasting”,
Renewable and Sustainable Energy Reviews, (Nisan 2015),
s.1352-1372.

Seppälä, A. :
“Load research and load estimation in electricity distribution”,
**Dissertation for the degree of Doctor, Helsinki University of
Technology**, 1996, s.12-13.

- Shilpa, G., N.;
Sheshadri, G. : “Short-Term Load Forecasting Using Arima Model for Karnataka State Electrical Load”, **International Journal of Engineering Research and Development**, Vol.13, Issue 7, 2017, s.75-79.
- Shukur, B.;
Fadhil, S.;
Lee, H.;
Ahmed, H.: “Electricity Load Forecasting using Hybrid of Multiplicative Double Seasonal Exponential smoothing Model with Artificial Neural Network”, **Jurnal Teknologi**, 69:2, 2014, s.65-70.
- Singh, S.;
Singh R. : “Arima Based Short Term Load Forecasting”, **Punjab Region. International Journal of Science and Research (IJSR)**, 2013, s.1819-1822.
- Souzo, R.,C.;
Barros, M.;
Miranda, C. : “Short Term Load Forecasting Using Double Seasonal Exponential Smoothing and Interventions to Account for Holidays and Temperature Effects”, **2º Taller Latino Iberoamericano de Investigación de Operaciones**, Acapulco, Guerrero, México, (Ekim 2007)
- Srivastava,A;
Pandey, Ajay, S. ;
Singh, Devender, : “Short-Term Load Forecasting Methods: A Review”, **International Conference on Emerging Trends in Electrical Electronics & Sustainable Energy Systems (ICETEESES)**, 2016
- Suhartone : “Time Series Forecasting by using Seasonal Autoregressive Integrated Moving Average: Subset, Multiplicative or Additive Model”, **Journal of Mathematics and Statistics**, 2011, s.20-27.

Taylor, J.: “Short-Term Electricity Demand Forecasting Using Double Seasonal Exponential Smoothing”, **The Journal of the Operational Research Society**, Vol.54, No.8, 2003, s.799-805.

Tınç, K. : “Tedarik Zincirinde İşbirlikçi Oyun Kuramı Kullanılarak Adil Kar Paylaşımının Yapılması Ve Enerji Sektöründe Uygulamalar”, **Doktora Tezi, İstanbul Teknik Üniversitesi Fen Bilimleri Enstitüsü**, 2018, s.59.

Wang, X., H.;
Cong, R.,G. : “Electric Power Supply Chain Management Addressing Climate Change”, **International Workshop on Information and Electronics Engineering (IWIEE)**, SciVerse ScienceDirect, Procedia Engineering, 2012, s.749-753.

Weron., R. : **Modelling and Forecasting Electricity Loads and Prices: A Statistical Approach**, John Wiley and Sons, Ltd., Chichester, 2006, s.1-2.

Yavuz, S. : “Hataları Ardışık Bağımlı (Otokorelasyonlu) olan Regresyon Modellerinin Tahmin Edilmesi”, **Atatürk Üniversitesi İktisadi ve İdari Bilimler Dergisi**, Cilt: 23, Sayı: 3, 2009, s.123-140.

European
Parliament : “Understanding electricity markets in the EU”,2016, (Çevrimiçi)
[http://www.europarl.europa.eu/RegData/etudes/BRIE/2016/593519/EPRS_BRI\(2016\)593519_EN.pdf](http://www.europarl.europa.eu/RegData/etudes/BRIE/2016/593519/EPRS_BRI(2016)593519_EN.pdf) ,
28.Ekim.2018.

Türkiye Elektrik
İletim A. Ş.: “Grafik III.I - 2017 Yılı Türkiye Elektrik Enerjisi Üretiminin
Kaynaklara Göre Dağılımı”, (Çevrimiçi)
<https://www.teias.gov.tr/tr/iii-elektrik-enerjisi-uretimi-tuketimi-kayıplar-0>, 10 Ekim 2018,

Türkiye Elektrik
İletim A. Ş.: “Kuruluş-Tarihçe” , (Çevrimiçi)
<https://www.teias.gov.tr/tr/hakkimizda/tarihce> , 12 Eylül 2018.

World Energy
Council: “World Energy Resources 2016”, October 3, 2016, (Çevrimiçi)
<https://www.worldenergy.org/wp-content/uploads/2016/10/World-Energy-Resources-Full-report-2016.10.03.pdf> , 11.Eylül.2018.

ÖZGEÇMİŞ

Ali Nadir Kapkın 1972 yılında İstanbul’da doğmuştur. Lisans Eğitimini 1997 yılında Trakya Üniversitesi Mühendislik Mimarlık Fakültesi Makine Mühendisliği, Master eğitimini ise 2006 yılında Marmara Üniversitesi Sosyal Bilimler Enstitüsü İşletme Anabilim Dalı Uluslararası Kalite Yönetimi Bilim Dalında tamamlamıştır. 2009 yılında İstanbul Üniversitesi Sosyal Bilimler Enstitüsü İşletme Anabilim Dalı Üretim bilim Dalı’nda Doktora programına kabul edilmiştir.

Yaklaşık 20 senedir Mekanik Taahhüt alanında çalışmakta olup, yerli ve yabancı menşeli projelerde sırasıyla saha mühendisi, şantiye şefi ve proje müdürü olarak görev almıştır. 2013 yılından beri kendi şirketinde Mekanik Taahhüt sektöründe çalışmaktadır.