

T.C
İSTANBUL KÜLTÜR ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

Makine Öğrenme Yöntemleri Yardımıyla
Tüketim İstatistiklerine Göre Talep Tahmini

YÜKSEK LİSANS TEZİ
MURATCAN ATALAY
1009051001

Anabilim Dalı: Bilgisayar Mühendisliği
Programı: Bilgisayar Mühendisliği

Tez Danışmanı: Yrd. Doç. Dr. Rüştü Murat Demirer

Eylül 2013

ÖNSÖZ

Tez çalışmam boyunca yardımlarını esirgemeyen, danışmanım, değerli hocam Sayın Yrd. Doç. Dr. Rüştü Murat DEMİRER'e, sevgisini ve desteği için kardeşim Burcu ATALAY'a ve annem Gönül SERT'e teşekkürü borç bilirim.

Muratcan Atalay

Eylül 2013

İÇİNDEKİLER

ÖNSÖZ.....	ii
İÇİNDEKİLER	iii
KISALTMALAR	vi
TABLO LİSTESİ	vii
ŞEKİL LİSTESİ.....	viii
TÜRKÇE ÖZET	x
İNGİLİZCE ÖZET	xii
1 GİRİŞ	1
1.1 TEZİN AMACI	1
2 ELEKTRİK TALEP TAHMİNİ.....	3
2.1 TANIMI	3
2.2 ZAMANA BAĞLI SINIFLANDIRILMASI.....	4
2.2.1 Uzun vadeli talep tahmini	4
2.2.2 Orta vadeli talep tahmini.....	5
2.2.3 Kısa vadeli talep tahmini.....	5
2.2.4 Çok kısa vadeli talep tahmini.....	5
2.3 TALEBİ ETKİLEYEN ETMENLER.....	5
2.3.1 Zamansal etmenler	6
2.3.2 Meteorolojik etmenler.....	7
2.3.3 Ekonomik etmenler	9
2.3.4 Rastlantısal etmenler	9
2.4 TALEP TAHMİNİNİ ZOR KILAN ÖZELLİKLER.....	9
2.4.1 Talep serilerinin durağan olmayışı.....	9
2.4.2 Kullanılan modelin uyumluluk zorunluluğu	10

2.4.3	Tahmin modelinin bağımlılığı	10
3	LİTERATÜR TARAMASI	11
3.1	TALEP TAHMİNİ TEKNİKLERİ	11
3.2	TALEP TAHMİNİ TEKNİKLERİNİN SINIFLANDIRMASI.....	11
3.2.2	Talep sinyalinin ön işlenmesi.....	12
3.3	LİTERATÜRDEKİ ÇALIŞMALAR	13
4	KULLANILAN MAKİNE ÖĞRENMESİ - REGRESYON YÖNTEMLERİ	21
4.1	YAPAY SİNİR AĞLARI.....	21
4.1.1	Talep tahmininde yapay sinir ağları.....	21
4.1.2	Yapay sinir ağlarının yapısı	22
4.2	DESTEK VEKTÖR MAKİNELERİ	24
4.2.1	Destek vektör makinelerinin yapısı.....	25
4.2.2	Destek vektör makineleri parametreleri	27
4.3	RASTLANTISAL ORMANLAR.....	29
4.3.1	Karar ağaçları	29
4.4	DOĞRUSAL REGRESYON.....	31
5	KULLANILAN DİĞER TEKNİKLER	32
5.1	PARÇACIK SÜRÜ OPTİMİZASYONU.....	32
5.1.1	Algoritmanın adımları.....	32
5.2	DİFERANSİYEL EVRİM.....	33
5.2.1	Algoritma adımları	33
5.3	TEMEL BİLEŞENLER ANALİZİ.....	34
5.3.1	Algoritmanın adımları.....	34
5.4	MAZGAL TARAMASI.....	35
6	GERÇEKLEME.....	37

6.1	ÖZELLİK VEKTÖRÜ SEÇİMİ	37
6.2	HATA KRİTERİ.....	39
6.3	GELİŞTİRME ORTAMI	39
6.4	DESTEK VEKTÖR MAKİNELERİ PARAMETRE SEÇİMİ.....	40
6.4.1	Destek vektör makinesi parametre uyumluluğu.....	40
6.4.2	Otomatik parametre seçimi	41
6.5	YAPAY SİNİR AĞLARI PARAMETRELERİ	42
6.6	RASTLANTISAL ORMANLAR.....	43
7	SAYISAL SONUÇLAR.....	44
7.1	EUNITE VERİ KÜMESİ	44
7.1.1	EUNITE veri kümesi üzerine diğer çalışmalar	49
7.2	TİCARİ İŞLETME TÜKETİMLERİNDEN OLUŞTURULAN VERİ KÜMESİ.....	49
7.3	TEMEL BİLEŞENLER ANALİZİNİN HATA ORANINA ETKİSİ..	55
	SONUÇLAR VE TARTIŞMA	56
	KAYNAKLAR	58
	ÖZGEÇMİŞ.....	63

KISALTMALAR

AGC:	Automatic Generation Control
PMUM:	Piyasa Mali Uzlaştırma Merkezi
SVM :	Support Vector Machine
YSA:	Yapay Sinir Ağları
RO:	Rastlantısal Ormanlar
RBF:	Radial Basis Function
PSO:	Particle Swarm Optimization
DE:	Differential Evolution
PCA:	Principle Component Analysis
ARMA:	Autoregressive Moving Average
ARMAX:	Autoregressive Moving Average Exogenous
ARIMA:	Autoregressive Integrated Moving Average
SARIMA:	Seasonal Autoregressive Integrated Moving Average
RCNL:	Regularized Negative Correlation Learning
MAPE:	Mean Absolute Percentage Error
EUNITE:	European Network on Intelligent Technologies for Smart Adaptive Systems

TABLO LİSTESİ

Tablo 6.1 Literatürdeki çalışmalarda kullanılan özellik vektörleri.....	37
Tablo 7.1 EUNITE veri kümesi üzerinde metotlara göre hata oranları.....	44
Tablo 7.2 EUNITE veri kümesi üzerinde destek vektör makineleri ile yapılan tahminler	46
Tablo 7.3 Yapay sinir ağları, rastlantısal ormanlar ve doğrusal regresyon ile yapılan tahminler	48
Tablo 7.4 Ticari işletme veri kümesi üzerinde metotlara göre hata oranları	50
Tablo 7.5 Ticari işletme veri kümesi üzerinde destek vektör makineleri ile yapılan tahminler	51
Tablo 7.6 Ticari işletme veri kümesi üzerinde yapay sinir ağları, rastlantısal ormanlar ve doğrusal regresyon ile yapılan tahminler	53

ŞEKİL LİSTESİ

Şekil 2.1 Yıl içerisinde değişen günlük maksimum talep	6
Şekil 2.2 Talep tahmininde haftalık çevrimler	7
Şekil 2.3 Sıcaklık ile günlük maksimum talep arasındaki korelasyon.....	7
Şekil 2.4 Gün uzunluğu ile günlük maksimum talep arasındaki korelasyon	8
Şekil 4.1 Sinir hücresinin yapısı	22
Şekil 4.2 Yapay sinir hücresinin yapısı.....	23
Şekil 4.3 Yapay sinir ağlarında sıkça kullanılan aktivasyon fonksiyonları	23
Şekil 4.4 İleri besleme yapay sinir ağı yapısı.....	24
Şekil 4.5 Destek vektör makinelerinde epsilon-duyarsız tüp.....	26
Şekil 4.6 Destek vektör makinesi aşırı uyum örneği	28
Şekil 4.7 Örnek banka kredi başvurusu karar ağacı.....	30
Şekil 7.1 EUNITE veri kümesi üzerinde metotlara göre hata oranları	44
Şekil 7.2 EUNITE veri kümesi üzerinde gerçek değerler ve SVM-PSO ile yapılan tahminler	45
Şekil 7.3 EUNITE veri kümesi üzerinde gerçek değerler ve SVM-DE ile yapılan tahminler	45
Şekil 7.4 EUNITE veri kümesi üzerinde gerçek değerler ve SVM-MAZGAL ile yapılan tahminler.....	46
Şekil 7.5 EUNITE veri kümesi üzerinde gerçek değerler ve yapay sinir ağları ile yapılan tahminler.....	47
Şekil 7.6 EUNITE veri kümesi üzerinde gerçek değerler ve rastlantısal ormanlar ile yapılan tahminler.....	47
Şekil 7.7 EUNITE veri kümesi üzerinde gerçek değerler ve doğrusal regresyon ile yapılan tahminler.....	48
Şekil 7.8 EUNITE veri kümesi üzerine literatürdeki diğer çalışmalar	49
Şekil 7.11 Ticari işletme veri kümesi üzerinde metotlara göre hata oranları.....	50

Şekil 7.12 Ticari işletme veri kümesi üzerinde gerçek değerler ve SVM-PSO ile yapılan tahminler.....	50
Şekil 7.13 Ticari işletme veri kümesi üzerinde gerçek değerler ve SVM-DE ile yapılan tahminler	51
Şekil 7.14 Ticari işletme veri kümesi üzerinde gerçek değerler ve SVM-MAZGAL ile yapılan tahminler.....	51
Şekil 7.15 Ticari işletme veri kümesi üzerinde gerçek değerler ve yapay sinir ağları ile yapılan tahminler.....	52
Şekil 7.16 Ticari işletme veri kümesi üzerinde gerçek değerler ve rastlantısal ormanlar ile yapılan tahminler.....	53
Şekil 7.17 Ticari işletme veri kümesi üzerinde gerçek değerler ve doğrusal regresyon ile yapılan tahminler.....	53
Şekil 7.18 Temel bileşenler analizinin hata oranına etkisi.....	55

TÜRKÇE ÖZET

Elektrik enerjisi, doğası gereği büyük ölçeklerde depolanabilir değildir. Bu sebepten ihtiyaca uygun şekilde anlık üretilmelidir. Üretimin güvenilir bir şekilde sürdürülebilmesinde planlama önemli rol oynamaktadır. Hidroelektrik santrallerinde rezervuarda biriktirilen su, termal sistemlerde stoklanan yakıt miktarı ve aktif halde tutulan birim sayısı gibi kararlar elektrik üretim altyapısının kârlılığını birincil derecede etkilemektedir. Üretim planlamasının hayati bileşeni ise geleceğe dönük talep tahminidir.

Talep tahmini, sektörel önemi ve tüketim örüntülerinin karmaşıklığı gereği açık araştırma konularından biridir. Bu problem üzerinde literatürde birçok farklı yöntem denenmiştir. Talebi zaman serisi olarak ele alan, talebin bileşenlerini doğrusal olarak modelleyen sistemler yanında doksanlardan itibaren makine öğrenmesi teknikleri öne çıkmaya başlamıştır. Makine öğrenmesi teknikleri geçmiş verilere dayanarak, tüketim ile etkileyen etmenler arasındaki doğrusal olmayan ilişkileri insan yardımı olmaksızın temsil edebilmektedirler. Ticari ürünlerin büyük çoğunluğunda kullanılan yapay sinir ağlarıyla beraber nispeten yeni destek vektör makineleri gibi teknikler de uygulanmaktadır.

Bu çalışmada, ilki beş bin ticari işletmenin, ikincisi tüm Doğu Slovakya'nın toplam elektrik taleplerini içeren iki farklı veri kümesi kullanılmıştır. Sistem yüklerinin meteorolojik ve zamansal etmenler arasındaki bağımlılıkları dört farklı makine öğrenmesi tekniğiyle modellenerek başarımları karşılaştırılmıştır. Bu modellerden biri olan destek vektör makinelerinin, eğitim aşamasından önce ihtiyaç duyduğu parametre seçiminde üç farklı üst sezgisel yöntem denenmiş ve modelin başarımlarındaki etkileri araştırılmıştır. Özellik vektörü bileşenlerinin azaltılmasında temel bileşenler analizi kullanılmış ve başarımların artışı incelenmiştir.

Anahtar kelimeler: kısa vadeli talep tahmini, maksimum talep tahmini, yapay sinir ađları, destek vektör makineleri, rastlantısal ormanlar, parçacık sürü optimizasyonu, diferansiyel evrim, temel bileşenler analizi

İNGİLİZCE ÖZET

In large scales, electrical energy cannot be stored due to its nature. For this reason it has to be produced balancing the momentary request. Production planning plays a vital role for the production to be secure and reliable. Planning covers decisions like the release program of water kept in the reservoirs of hydroelectric systems, the amount of fuel stocked at a thermal system, active generator unit count. The vital component that production planning relies is the load forecasting.

Load forecasting is an open research area because of its commercial value and complexity of the consumption patterns. Literature contains a number of techniques studied. Along with the methods that approaches the load as a time series and models that make linear approximations of the components of load signal, machine learning methods started to come forward since early 1990s. These methods can approximate non-linear dependencies between the load and the exogenous factors by processing historical data. Along with artificial neural networks, which has a wide range of commercial implementations, relatively new models like support vector machines are also being applied to problem.

On this study, we have used two datasets. One containing sum of five thousand commercial consumers, the other total consumption of East Slovakia. The dependencies between meteorological and time factors were modelled by four different machine learning methods and success of each were compared. One of these models, support vector machines, needs a parameter selection process before the training. We have used three meta-heuristics algorithms for parameter selection and compared the results. Principal component analysis was used for feature reduction and its effects to performance was analyzed.

Keywords: short term load forecasting, peak load forecasting, artificial neural networks, support vector regression, random forest, particle swarm optimization, differential evolution, principal component analysis

1 GİRİŞ

1.1 Tezin amacı

Elektrik talebi; zamansal, meteorolojik ve benzeri birçok değişimden etkilenen bir dinamik sistem olarak tanımlanabilir. Bu çalışma, doğrusal olmayan özbağlanımlı yöntemlere dayalı kısa vadeli(erimli) elektrik talep tahmini uygulamasına dayanır.

Gerek literatürde gerekse ticari uygulamalarda makine öğrenmesi yöntemleri doksanlı yılların başından bu yana bu alanda da öne çıkmaktadır. Bu çalışmada, literatürdeki dikkate değer yayınlar incelenmiş, sıkça kullanılan dört makine öğrenmesi yöntemi incelenerek uygulanmıştır.

Uygulamada, literatürdeki bazı çalışmalarda da atıfta bulunulan EUNITE elektrik talep tahmini yarışmasında kullanılan veri kümesi ve beş bin ticari işletmenin toplam talepleri kullanılarak, makine öğrenmesi yöntemlerinin meteorolojik ve astronomik etmenler ile elektrik talebi arasındaki ilişkiyi modelleyebilme başarıları karşılaştırılmıştır.

Uygulanan makine öğrenmesi yöntemlerinden biri olan destek vektör makinelerinin başarımı, üst-sezgisel yöntemlerle birleştirilerek arttırılmıştır. Bu üst sezgisel yöntemler arasında klasik olarak mazgal taraması yardımıyla yapılan parametre seçimleri, parçacık sürü optimizasyonu ve diferansiyel evrim yaklaşımları kullanıldığında başarımın daha yüksek olduğu saptadık.

Ayrıca, makine öğrenmesi yöntemlerinin başarımını ve öğrenme performansını arttıran tekniklerden biri olan temel bileşenler analizi yöntemi kullanılarak başarıma etkisi incelenmiştir.

Bu alıřmada; Blm 2’de talep tahmini, gerekleri ve problemin doęası ortaya konmuř, Blm 3’de literatrdeki ilgili alıřmalar ve sınıflandırmaları anlatılmıřtır. Blm 4 ve Blm 5’de alıřma dhilinde gerekleřtirdiđimiz uygulamada kullanılan teknikler tanıtılmıřtır. Blm 6’da ise uygulama detayları ortaya konmuřtur. Blm 7’de sayısal sonular yer almaktadır.

2 ELEKTRİK TALEP TAHMİNİ

2.1 Tanımı

Elektrik, il ve ilçeler ölçeğinde ele alındığında, stoklanabilen bir enerji çeşidi değildir. İhtiyaç olduğu anda üretilmeli ve tüketilmelidir. Elektrik şebekesinin güvenilir ve sağlıklı bir şekilde işleminin ön koşulu, arz talep dengesinin ivedilikle kurulabilmesidir.

Üretimin ihtiyaçtan fazla planlanması kârlılığı düşürecek, az olması ise tüm şebekenin kapanarak hizmet veremez hale gelmesine veya şebeke dışından enerji alımına sebep olacaktır. Bundan dolayıdır ki üretim ve yatırım planlaması, enerji üretim/dağıtım süreçlerinin en kritik aşamalarından biridir.

Üretim planlamasının kapsamında yakıt satın alımı ve stoklanması, jeneratör birimlerin aktif/pasif hale getirilmesi, barajlarda suyun rezervuardan salınımının programlanması, bakım zamanlarının kârı maksimize edecek şekilde belirlenmesi gibi kararlar alınmalıdır. Bu kararların alınmasında en önemli etmen geleceğe dönük elektrik talep tahminidir.

Yakın tarihte tüm dünyada elektrik alt yapısı özelleştirmeye yönelik bir eğilim söz konusudur. Daha önceden var olmayan, serbest üretici, serbest tüketici, oto-produktör gibi aktörler de piyasaya dahil olmuştur. Devlet tekelinden çıkarak farklı aktörlerin kontrolüne giren üretim ve dağıtım alt yapısının denge ve senkronizasyonu devlet dâhilinde faaliyet gösteren PMUM gibi kuruluşlar tarafından sağlanmaktadır. Bu kurumlar, dağıtım şirketlerinin kısa vadeli taleplerini periyodik olarak toplayarak üretici ve dağıtıcılar arasındaki dengeyi kurmakla yükümlüdürler. Bu noktada talep tahmini, üreticinin olduğu kadar yerel bazda dağıtım şirketinin de yükümlülüğü haline gelmektedir.

Elektrik talep tahmini kabaca, gelecekte elektrik talebinin ne olacağını öngörmedir. Farklı amaçlarla birçok farklı zaman aralığı için tahminde bulunulur.

Zamana baęlı olarak drt farklı bařlık altında incelenebilir.

- Uzun vadeli talep tahmini
- Orta vadeli talep tahmini
- Kısa vadeli talep tahmini
- ok kısa vadeli talep tahmini

Hedef bazlı incelendięinde ise drt farklı bařlıkta incelenebilir;

- Yerel bazda maksimum anlık talep
- Gnn belli saatlerinde sistemdeki talep
- Saatlik veya yarım saatlik talep
- Gnlk ve haftalık sistem talebi

Talep tahmini ekonomik olarak byk neme sahiptir. Dřk yapılan tahmin gerekli rezervlerin ayrılmamasına ve yksek talep anında sistem dıřından elektrik alınmasına veya kmesine, aksi ise, fazla yakıt stoklama, gereksiz yere alıřtırılan niteler ve benzeri sebepler yznden maliyetleri ykseltecektir. 1985 yılında, byk oranda termik sistemler kullanan İngiltere'de yapılan bir alıřmaya gre talep tahminindeki %1'lik hata yıllık 10 milyon £'a yakın zarara sebep olmaktadır [1].

2.2 Zamana baęlı sınıflandırılması

2.2.1 Uzun vadeli talep tahmini

5-20 yıl ileriye dnk yapılan tahminleri kapsar. Normal olarak kapasite bytme ve yatırımların planlanması amacıyla kullanılır. Yeni alt istasyonların, yeni hatların kurulması veya var olanların kapasitelerinin ykseltilmesi ana konusudur [2].

2.2.2 Orta vadeli talep tahmini

Tahmin zamanı bir kaç ay ile bir kaç gün arasında değişir. Birincil hedefi mevsimsel etkilerin en etkili olduğu zamanlar için alt yapının kapasitesinin yeterli olup olmadığını tespit etmektir [2].

2.2.3 Kısa vadeli talep tahmini

Tipik olarak, saatlik ve günlük dönemlerle 1 haftalık zaman dilimini kapsar. Birincil derecede önemli operasyonel kararlara dayanak oluşturur. Hidroelektrik sistemlerinde rezervardaki suyun optimum salınım programı, termik sistemlerde birim adamasının programlanması, üretimin fiziksel, çevresel ve donanımsal kısıtlara uygun olarak planlanması gibi önemli süreçlerde kullanılır. Yakından ilişkili olarak dağıtım/üretim şirketlerinin birbirleri arasındaki enerji takası için de kullanılmaktadır [2].

2.2.4 Çok kısa vadeli talep tahmini

Bir kaç saniye ile 1 saat aralığını kapsar. Çok kısa vadeli talep tahmini sistemleri otomatik jeneratör kontrol (AGC) ünitelerine gömülü olarak koşmakta, otomatik olmayan sistemlerde operatörler için karar destek sistemi olarak çalışmaktadır. Bunun yanı sıra enerji borsasının varlığında alım-satım işlemleri için danışman olarak kullanılmaktadır [2].

Elektrik talep tahmini sadece üretim odaklı değildir. Dağıtım hatlarına yapılacak yatırım kararlarında da anahtar rol oynamaktadır. Hatların ve alt sistemlerinin belirli maksimum güç kapasiteleri vardır. Kapasitenin üstünde bir güç dağıtımı elektrik şebekesinde güvenlik sorunlarına yol açacaktır. Dolayısıyla toplam talep yanında günlük maksimum talep tahmini de dağıtım şirketleri için önemli bir araçtır. Trafo/ana indirici trafo sistemlerinin yenilenmesi, yeni hat yatırımları maksimum güç tahmini kullanılarak en düşük maliyetle yapılmaya çalışılır [2].

2.3 Talebi etkileyen etmenler


Elektrik sisteminin davranışı birçok sayıda dış etmenden etkilenmektedir. Bu etmenleri dört başlık altında sınıflandırabiliriz; [1]

- Ekonomik etmenler


- Zamansal etmenler
- Meteorolojik etmenler
- Rastlantısal etmenler

2.3.1 Zamansal etmenler

Elektrik tüketimi zamansal etmenlerden büyük ölçüde etkilenmektedir. Haftalık ve günlük çevrimler, mesai saatleri, günlük güneşlenme süresi, yaz saati uygulaması ve tatil gibi değişkenler büyük ölçüde tüketime etki eder. Bunun yanı sıra bayramlar, okulların açılması gibi önemli toplumsal olaylar da tüketimde değişikliğe sebep olmaktadır. Dini ve resmi bayramlar da tüketimin normal değerlerin altına düşecek şekilde azalmasına sebep olur [1].




Şekil 2.1 Yıl içerisinde değişen günlük maksimum talep



Şekil 2.2 Talep tahmininde haftalık çevrimler


2.3.2 Meteorolojik etmenler

Talep tahmin sistemlerindeki en önemli parametrelerden biri hava sıcaklığıdır.




Şekil 2.3 Sıcaklık ile günlük maksimum talep arasındaki korelasyon

Hava sıcaklığı özellikle ısıtma-soğutma için elektrik kullanılan ve tarımsal sulama yapılan bölgelerde önemli dalgalanmalara yol açmaktadır. Anlık sıcaklığın yanı sıra, peşi sıra devam eden sıcak günler de sistemde farklılıklara yol açmaktadır.



Nem, hava basıncı, ani hava değişimleri de ve gün uzunluğu gibi değerler de sistem yükünde büyük etkiye sahiptir. Özellikle yenilenebilir enerji kaynaklarının kullanıldığı bölgelerde, güneşlenme süresi ve rüzgâr hızı da tahminlerde göz ardı edilmemesi gereken etmenlerdendir [1].



Şekil 2.4 Gün uzunluğu ile günlük maksimum talep arasındaki korelasyon

2.3.3 Ekonomik etmenler

Elektrik tüketiminin büyük çoğunluğu endüstriyel, ticari ve tarımsal alanda kullanılmaktadır. Bu sebepten dolayı, ekonomik dalgalanmalar elektrik tüketiminde büyük rol oynar [1]. Sanayi kapasite kullanım oranı, endüstriyel aktivite, tarımsal sulama dönemleri gibi etmenler sistemi büyük ölçüde etkilemektedir. Tipik olarak bu etkiler uzun vadeli tahminlerde etkili olmaktadır. Bir kaç yıl veya mevsim sonrasında kapsayan tahminlerde kullanılırlar. Kısa vadeli tahminlerde etkileri nispeten azdır.

2.3.4 Rastlantısal etmenler

Elektrik dağıtım/üretim sistemleri aynı zamanda tahmin edilemeyecek etkilere de maruz kalmaktadır. Rüzgâr tünelleri, döküm tesisleri gibi yüksek güç ihtiyacı olan işletmelerin operasyon programları bilinemediğinden tüketimde büyük dalgalanmalar yaşanabilmektedir. Bunun yanı sıra grev, protesto veya büyük endüstriyel tesislerin kapatılması gibi olaylar sistemi etkilemektedirler [1].

Kısacası elektrik tüketimi meteorolojik, zamansal ve ekonomik faaliyetlerden etkilenen durağan olmayan ve rastlantısal bir zaman serisi olarak düşünülebilir.

2.4 Talep tahminini zor kılan özellikler

Sistem yükünün rastlantısal benzeri davranışı ve etkileyen faktörlerle arasındaki doğrusal olmayan ilişki sebebiyle üzerinde çalışılması zor bir problemdir. Talep tahminini zor ve araştırmaya açık kılan temel özellikler bulunmaktadır [3].

2.4.1 Talep serilerinin durağan olmayışı

Talep serileri, durağan süreçler değildir. Sürecin varyans ve kovaryansı zamanla değişebilmekte, farklı eğilimlere girebilmektedir. Tüketim alışkanlıklarının değişmesi, mevsimsel etkiler ve fiyat değişiklikleri gibi etmenler çoğunlukla durağanlığın kısıtlı süreler içinde kalmasına sebep olmaktadır. Bu yüzden kullanılan yöntemin sistem yükü ile etkileyen etmenler arasındaki dinamik girdi-çıkı ilişkisini modelleyebilmesi önemlidir. Durağanlık varsayımı büyük tahmin hatalarına sebep olmaktadır [3].

2.4.2 Kullanılan modelin uyumluluk zorunluluđu

Konu hakkındaki gemiř alıřmalarla, talebin iř gnleri, hafta sonları ve bayram, tatil gibi anormal gnlerde byk farklılık gsterdiđi grlmřtr. Dolayısıyla seilen model farklı tipte gnlere adapte olabilmelidir

2.4.3 Tahmin modelinin bađımlılıđı

Tecrbelere gre, talep tahmini iin ykn kendisi dıřında birok etmen de (gn tipi, saat, sıcaklık, nem, rzgr hızı) tahmin srecine dhil edilmelidir. Bu deđiřkenler birden ok girdi-ıktıya sahip yapay sinir ađları gibi tekil bir modeller zerinden kullanılmaktadır. Elde edilen modellerin sistem bađımlı olması farklı retim/dađıtım řirketleri iin uygulamayı zorlařtırmaktadır. Bu bađlamda evrensel bir model tm elektrik mhendislerinin ilgisini ekecektir [3].

3 LİTERATÜR TARAMASI

3.1 Talep tahmini teknikleri

Talep tahmini için literatürde oldukça farklı modeller ve teknikler uygulanmıştır. Sistemdeki anlık talep, birbirinden bağımsız tüketicilerin bileşiminden oluşmuştur. Bu bileşenler, tek başlarına incelendiğinde rastlantısal; tahmin edilemez davranmaktadırlar. Ancak bileşenlerin toplamı istatistiki olarak tahmin edilebilir özelliktedir.

3.2 Talep tahmini tekniklerinin sınıflandırması

Literatürdeki talep tahmini tekniklerinin geneli sistem yükünü geçmiş tüketim verileri ve/veya tüketimi etkileyen etmenleri parametre kabul edilerek matematiksel model oluşturmaya dayanmaktadır. Bu yöntemler üç geniş kategoriye ayrılabilir; [4]

- Parametrik yöntemler
- Parametrik olmayan yöntemler
- Yapay zekâ yöntemleri

3.2.1.1 Parametrik yöntemler

Yük ile onu etkileyen etmenler arasındaki niteliksel bağıntıları inceleyerek matematiksel veya istatistiki olarak formüle eden tekniklerdir. Bazı örnekleri; açık zaman fonksiyonları, polinomsal fonksiyonlar, Fourier serileri ve çoklu doğrusal regresyon modelleridir [4].

3.2.1.2 Parametrik olmayan yöntemler

Gelecekteki talebin sadece geçmiş tüketim verilerine dayandırılarak tahmin edilmesine olanak sağlar. Örneğin parametrik olmayan regresyon kullanarak talep tahmini geçmiş taleplerin yerel komşuluğunun ortalaması olarak hesaplanabilir [4].

Zaman serisi metotları bu başlık altında incelenebilir. Bu metotlar talebi; mevsimsel, haftalık ve günlük devinimleri bilinen zaman serisi sinyali olarak ele alır. Etkileri bilinen bu çevrimler, verilen bir mevsim, haftanın günü ve günün saatindeki talebi ortalama olarak verebilir. Periyodik değerler ile gerçek değerler arasındaki fark stokastik süreç (rastlantısal sinyal) olarak kabul edilir. Rastlantısal sinyallerin analizini için Kalman filtreleme, Box-Jenkins metotları kullanılabilir [5]. Literatürdeki çalışmalarda kullanılan bazı yöntemlerin örnekleri ise aşağıdadır;

- Box & Jenkins [6]
- ARMA ve türevleri [7] [8]
- Kaos zaman serileri [9]

3.2.1.3 Yapay zekâ yöntemleri

Yapay zekâ metotları için daha çok yapay sinir ağları ve destek vektör makineleri kullanılır. Bu metotların en büyük avantajı direkt bir model belirtilmeksizin bilinen bağımlılıkları tarihsel verilerden direkt olarak öğrenebilmeleridir [5].

- Yapay sinir ağları [4] [10] [11] [12] [13] [14] [15] [16]
- Destek vektör makineleri [17] [18] [19] [3] [20] [2]
- Yapay sinir ağları – Bulanık mantık melez sistemler [21] [22] [23] [24] [25] [26]
- Uzman sistemler [25]
- Bulanık mantık sistemleri [13] [27]

3.2.2 Talep sinyalinin ön işlenmesi

Literatürdeki çalışmalarda, geçmiş talep verisi çeşitli tekniklerle işlenerek kullanılan matematiksel veya istatistikî modelin tahmin başarımı artırılmıştır. Bu teknikler çoğunlukla geçmiş talep verisinin daha kolay öğrenilebilecek parçalara ayırarak işlenmesi temellidir. İki temel yaklaşım bulunmaktadır;

- Geçmiş talebin gün bazında birbirinden ayrılması (hafta içi, hafta sonu, bayram, anormal meteorolojik durumlar)

- Geçmiş talep verisini bir sinyal olarak ele alınarak farklı frekanslardaki bileşenlerin ayrılması

Gün bazında ayırım, denetimsiz öğrenme algoritmaları yardımı ile talebin gün içerisindeki saatlik değişimini inceleyerek yapılmaktadır. Bunun için karınca kolonisi optimizasyonu kümelemesi, Kohonen ağı gibi algoritmalarından yararlanır [14] [15]. Frekans bazındaki ayırım ise bir sinyal olarak ele alınan talebin, farklı frekanslardaki bileşenlerinin farklı sinyallermişçesine modellenmesiyle gerçekleştirilir. Dalgacık dönüşümü frekans ayırımı en çok kullanılan tekniktir [10].

Her iki yöntemde de, ayrılan bileşenler izole olarak işlem görür ve tahminler nihai sonucu oluşturacak şekilde birleştirilir.

3.3 Literatürdeki çalışmalar

Charytoniuk ve Chen [4], yapay sinir ağları kullanarak çok kısa vadeli talep tahmini üzerine çalışmıştır. Özellik vektörlerinin bileşenleri seçilirken girdiler ile çıktılar arasında doğrusal korelasyon analizi yapılmış ve temel bileşenler analizi ile mükerrer bilgi azaltılmıştır. Çalışmanın sonucunda 60 dakika ilerisi için hata değerleri -%10,+%8 arasında, 20 dakika için -%4,+%3 arasında değişmektedir.

Sinha ve diğerlerinin [10] çalışmasında talep bir sinyal olarak ele alınmış ve dalgacık dönüşümü (wavelet transform) kullanılarak farklı frekans aralığındaki bileşenlerine ayrılmıştır. Her bir bileşen için ayrı bir yapay sinir ağı eğitilmiş ve bileşenlerin ayrı tahminleri başka bir sinir ağı ile birleştirme için eğitilmiştir. Sinir ağlarının eğitiminde genetik algoritma kullanılmıştır.

Liao ve Tsao [21] yapay sinir ağları ve bulanık mantık çıkarım motorunu bir arada kullanan melez sistemle normal haftalar için % 1.25 ortalama mutlak yüzdelik hataya kadar (MAPE, Bölüm 6.2) sonuçlar almıştır.

De Felice ve Yao [11] çalışmalarında yapay sinir ağı topluluk öğrenmesi metotları inceleyerek, tüketici bazında talep tahmin için karşılaştırma yapmıştır. SARIMA ve RCNL yapay sinir ağı ile yapılan karşılaştırmada, sinir ağlarının daha yüksek başarımlar sağladığı ortaya konmuştur.

Sanchez ve diğerlerinin [12] çalışmasında yapay sinir ağı, kalman filtreleme metoduyla eğitilmiştir. Kullanılan ağ özyineli olup, klasik ileri besleme ağlara göre daha yüksek başarımlar elde edilmiştir.

Chen ve diğerleri [17], çalışmalarında destek vektör makineleri kullanarak EUNITE elektrik talep tahmin yarışmasında kazanan uygulamayı detaylandırmıştır. Bu çalışmada hedef aydaki ortalama mutlak yüzdeler hata oranı %2.47 olmuştur.

Michanos ve diğerleri [9] çalışmalarında kaos zaman serilerini kullanarak %4.723-%5.008 yüzdeler hata oranına ulaşmıştır.

Liu ve diğerleri [13] çok kısa zamanlı talep tahmini yöntemlerinin karşılaştırmasını yapmıştır. Bu karşılaştırmada, pratikte kullanılan üç metod; bulanık mantık, yapay sinir ağı ve özbağlanımlı modeller kullanılmıştır. Sonuç olarak, bulanık mantık ve yapay sinir ağlarının, özbağlanımlı modellere göre daha iyi adaylar oldukları ortaya konmuştur.

Meng ve diğerlerinin [14] çalışmasında yapay sinir ağı ve karınca yuvası kümeleme metotları birlikte kullanılarak modelin başarımlarını artırılmıştır. Kullanılan modelde maksimum hata oranı %2 olmuştur.

Abbas ve Arif [18] EUNITE talep tahmini yarışması verilerinde baz aldıkları çalışmalarında gün bazında kümeledikleri veriyi destek vektör makineleri kullanarak modellemiştir. Haftanın her günü için ayrı bir model kullanılması başarımların artmasını sağlamış, ortalama mutlak hata oranı %1.93 olmuştur.

Mori ve Yuihara [15] çalışmalarında deterministik tavlama benzetimi (deterministic annealing) kümeleme yöntemiyle kümeledikleri talep verisini yapay sinir ağları yardımıyla eğitmiştir. Kümelemenin ortalama hatayı %0.254 maksimum hatayı %1.249 düşürdüğü gözlemlenmiştir.

Saini ve Soni [16] çalışmalarında yapay sinir ağlarını eşlenik gradyan metotlarıyla eğiterek maksimum talep tahmini yapmıştır. Bu çalışmada ortalama mutlak yüzdelik hata oranı ertesi gün için %1.36'ya kadar düşürülebilmektedir.

Senjyu ve diğerleri [22] çalışmalarında “ertesi gün maksimum talep tahmini” için bulanık mantık ve yapay sinir ağları melez bir model geliştirmiştir. Bulanık mantık yardımı ile hata oranı %23 oranında azalmış ve melez sistemin ortalama mutlak hata oranı %1.71 olmuştur.

Elattar ve diğerleri [19] çalışmalarında destek vektör makinesi regresyonunun geliştirilmiş bir sürümüyle talep tahmini uygulaması yapmıştır. Yerel ağırlıklı destek vektör makinesi olarak adlandırdıkları bu metot ile %1.34 ortalama mutlak yüzdelik hata oranına ulaşmışlardır.

Marin ve diğerlerinin [28] çalışmalarında kısa vadeli talep tahmini için Elman özyineli yapay sinir ağları kullanılmıştır. İspanya bölgesinden elde ettikleri talep verisi için %1.42 ile %2.19 arasında değişen ortalama mutlak hata oranlarına ulaşmıştır.

Liang ve Cheng [27] çalışmalarında bulanık mantık ve regresyonu birleştirildiği bir model geliştirmiştir. Bu modelin 24 saatlik tepe yük tahmininde etkili olduğu ortaya konmuştur. Ortalama mutlak hata oranı %1.94 olmuştur.

Saini ve Soni [29] çalışmalarında yapay sinir ağını Levenberg-Marquardt algoritmasıyla eğiterek 1-7 gün sonrası talep tahmini için %2 ila %3 arasında değişen

ortalama mutlak yzdelik hata oranını yakalamıřtır. 11 farklı meteorolojik gzlem verisi temel bileřenler analizi ile kullanılmıřtır.

Bashir ve El-Hawary [30] paracık sr optimizasyonu yardımıyla eđittikleri yapay sinir ađlarını, dalgacık dnřm kullanarak ayrılan bileřenlere uygulamıřtır. Uygulamada New York blgesinden sađlanan veri kullanılmıř, hafta ii ve hafta sonları ayrı olarak tahmin edilmiř ve %1.9882 hata oranına ulařılmıřtır.

AlFuhaid ve diđerlerinin [31] alıřmasında yapay sinir ađları basamaklanarak kullanılmıřtır. İlk basamaktaki model gn iin minimum/maksimum ve toplam talep tahmini yaparken, ikinci basamaktaki model ise tahmini yarım saatlik olarak detaylandırmıřtır. Bu řekilde ortalama hata %28.9, maksimum hata ise %54.7 azaltılmıřtır. Ortalama saatlik hata, aydan aya farklılık gstermek zere %1.635-%3.414 arasında olmuřtur.

Chen ve diđerleri [32] alıřmalarında dalgacık dnřm ile birlikte yapay sinir ađları kullanılmıřtır. Dalgacık dnřm sayesinde talep sinyali yksek ve alak olmak zere iki frekans bandına ayrılmıř ertesini gn iin talep tahmini yapılmıřtır. %1.42 ile %5.89 arasında deđiřen hata oranlarına ulařılmıřtır.

Vermaak ve Botha [33] alıřmalarında talep sinyalini meteorolojik, zamansal ve diđer etmenleri kullanarak modellemiřlerdir. zyineli yapay sinir ađları ile ileri besleme ađları karřılařtırmıř, ortalama hata zyineli ađlar iin %2.0237 ileri besleme ađlar iin ise %2.5673 seviyesinde olmuřtur.

Fan ve Chen [3] talep sinyalini Kohonen yapay sinir ađı ile denetimsiz olarak kmelere ayırmıř ve her bir kme iin destek vektr makinesini uygulamıřtır. Tek bir destek vektr makinesi ile modellendiđinde ortalama mutlak yzdelik hata oranı %2.71, her bir kmeye ayrı olarak uygulanan destek vektr makinesi ađı iin %2.06 olmuřtur.

Al-Hamadi ve Soliman'ın [23] çalışmasında doğrusal bulanık mantık modeli Kalman filtreleme ile kısa vadeli talep tahmini için kullanılmıştır. Kullanılan veri kümesi üzerinde yapılan diğer çalışmalarda; çoklu doğrusal regresyon %2.40, regresyon modeli %1.37, yapay sinir ağı-bulanık mantık melez sistem %1.07, Kohonen yapay sinir ağı ve dalgacık dönüşümü %0.98, paralel bulanık-yapay sinir ağları ile %0.83 ortalama mutlak yüzdelik hataya ulaşılmıştır. Bu çalışmada ise aynı değer %0.70 olmuştur.

Amjady'nin [6] çalışmasında talep sinyali zaman serisi olarak ele alınıp ARIMA kullanılarak modellenmiştir ve en düşük hata oranları saatlik talep tahmini için %1.54, maksimum talep tahmini için %1.44 olmuştur.

Rahman ve Hazim'in [34] çalışmasında kısa vadeli talep tahmini için geliştirilmiş bilgi tabanlı (knowledge-based) sistem kullanılmıştır. Bu yaklaşım, Massachusetts ve Washington bölgesinden elde edilen veri kümesine uygulanmış ve ortalama mutlak hata oranı %1.22 ile %2.7 arasında olmuştur.

Huang ve diğerlerinin [8] çalışmasında ARMAX modeli parçacık sürü optimizasyonu kullanılarak eğitilmiştir. Hata oranları mevsimlere ve gün tipine %0.87 ile %2.11 arasında değişmektedir.

Mao ve diğerlerinin [24] çalışmasında talep verisi Kohonen yapay sinir ağı ile kümelenecek ve her bir küme için melez bulanık-yapay sinir ağı eğitilmiştir. Eğitim için kullanılan EUNITE veri kümesinde başarı oranı %1.6076 olmuştur.

Kim ve diğerlerinin [35] çalışmasında talep tahminini anormal günlerin tahminine odaklanmıştır. Bu çalışmada günler öncelikle beş farklı sınıfa ayrılmış, her farklı sınıf için yapay sinir ağı eğitilmiş ve ağımların bulanık mantık çıkarım modeli tarafından düzenlenmiştir. 1996-1997 yıllarına ait elektrik tüketim verilerine uygulanan model, %1.78 ortalama yüzdelik başarı oranına ulaşmıştır.

Huang ve Shih'in [7] çalışmasında talep verisini ARMA kullanarak modellemiş ve Gaussian doğrulama prosedürü ile başarımlarını arttırmıştır. Bu metod ile ortalama yüzdelik hata %1.62, maksimum hata oranı %4.67 olmuştur.

Ling ve diğerlerinin [36] çalışmasında, çift aktivasyon fonksiyonuna sahip düzenlenmiş yapay sinir ağı kullanılmış ve genetik algoritma yardımıyla eğitilerek kısa vadeli talep tahminine uygulanmıştır. Bu çalışma sonucunda, klasik yapay sinir ağları %5.2094 ile %2.7665 arasında ortalama mutlak yüzdelik hata oranına sahip iken, önerilen ağ için bu değerler, %1.9120 ile %2.6807 olmuştur.

Abdel-Aal'ın [37] çalışmasında "abductive network" olarak adlandırdığı yapay sinir ağı topolojisi ile genelde %2.67 bir sonraki saat için %1.14 ortalama mutlak yüzdelik hata oranına ulaşmışlardır.

Yun ve diğerlerinin [25] çalışmasında bulanık mantık(ANFIS)-yapay sinir ağı melez sistem kullanarak sistemlerin kendi başlarına kullanımına nazaran daha yüksek başarımlar elde etmişlerdir. Ortalama mutlak yüzdelik hata oranının maksimum değeri %4.549 ortalama değeri %1.669 olarak hesaplanmıştır.

Drezga ve Rahman'ın [38] çalışmalarında kısa vadeli talep tahmini için kullanılması gereken etmenlerin belirlenmesi için bir çerçeve sağlamış ve bu amaçla kullanılabilecek yöntemleri tanıtmıştır.

Chang ve diğerleri [20] çalışmalarında EUNITE talep tahmini yarışmasında birinci olan tekniklerini detaylandırmıştır. Destek vektör makinesi kullandıkları teknik, yarışmada %2.2 ortalama mutlak yüzdelik hata oranına sağlamıştır.

Osman ve diğerleri [39] çalışmalarında önerdikleri olasılık temelli eğitim algoritmasıyla talep verisini ileri besleme yapay sinir ağları kullanarak

modellemişlerdir. Bu çalışmada ortalama mutlak yüzdelik hata; bahar ayları için %2.2, yaz için %1.04, sonbahar için %1.97 ve kış için %0.32 olmuştur.

Ming-guang [40] çalışmasında destek vektör makineleri yardımı ile talep tahmini yapmış ve yapay sinir ağlarından daha yüksek başarımlar elde ettiğini saptamıştır. Yapay sinir ağları için maksimum hata oranı %11.9 ortalama hata oranı %4.1 iken, destek vektör makineleri için aynı değerler %5.2 ve %2.4 olmuştur.

Jain A. ve Satish [2] çalışmalarında talep verisini kümeleyerek destek vektör makinesi yardımıyla modellemiş ve kümelemenin hem maksimum hata hem de ortalama hatayı düşürdüğünü saptamıştır.

Zhangang ve diğerleri [41] çalışmalarında genetik algoritma yardımıyla eğittikleri yapay sinir ağlarını kullanarak talep verisini modellemişler ve Grey model ile karşılaştırmışlar. Grey model ile hata %1.26, %4.53 arasında değişirken önerilen metod ile hata %0.40 ile %3.05 arasında olmuştur.

Song ve diğerlerinin [26] çalışmaları tatil günleri özelinde olup yapay sinir ağları ve bulanık mantık melez model kullanmışlardır. Bu metod ile maksimum ortalama mutlak yüzdelik hata %3.57 oranında olmuştur.

Bakirtzis ve diğerleri [42] Yunanistan Kamu Elektrik Şirketi için yaptıkları uygulamayı anlattıkları çalışmalarında, yapay sinir ağlarını kullanmış ve iş günleri için %2.24 tatiller için %3.56 ve tatili takip eden 2 gün için %4.00 ortalama yüzdelik hataya ulaşmışlardır.

Taylor ve Buizza'nın [43] çalışmasında yeni geliştirilen ve daha önceden talep tahminine uygulanmamış beş üstel ağırlıklı metodu (exponentially weighted methods) uygulayarak karşılaştırmıştır. Bu karşılaştırmada yeni metodlar var olan benzeri yöntemlere nispeten daha iyi sonuç vermiştir.

4 KULLANILAN MAKİNE ÖĞRENMESİ - REGRESYON YÖNTEMLERİ

4.1 Yapay sinir ağları

4.1.1 Talep tahmininde yapay sinir ağları

Son yıllarda talep tahmini problemi için araştırmacılar yapay sinir ağları üzerine odaklanmışlardır. Yapay sinir ağlarının iki önemli avantajı vardır. İlki herhangi bir fonksiyonu yaklaşık olarak temsil edebilmeleri diğeri ise, modelin öğrenme aşamasında eğitim algoritması tarafından otomatik olarak belirlenmesidir [26].

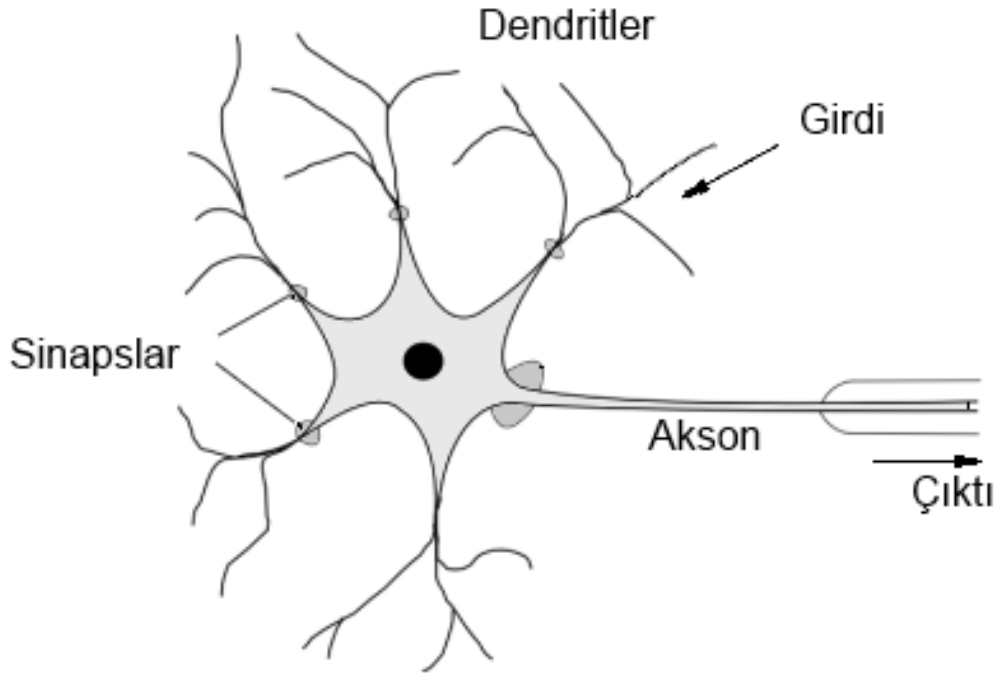
Talep sinyali ile etkileyen etmenler arasında doğrusal olmayan bağımlılıklar bulunmaktadır. Yapay sinir ağları aktivasyon fonksiyonları sayesinde lineer olmayan ilişkileri de temsil edebilmektedirler. Bu etmenler ve yakın geçmişteki talep verisi ağın girdileri, gelecekteki (ertesi gün/saat veya dakika) talep çıktısı olarak tanımlandığında, yapay sinir ağları geri besleme veya üst sezgisel algoritmalarla geçmiş veriler kullanılarak otomatik olarak eğitilebilmektedirler. Bu ise operatör destekli/kural bazlı sistemlere karşı büyük avantaj sağlamakta ve ticari ürünlerde tercih edilmesini sağlamaktadır.

Avantajlarının yanı sıra Yun Z. ve diğerlerinin [25] çalışmalarında belirttiği üzere insanların kolaylıkla yapabildiği muhakeme, sonuç çıkarma yeteneğinden yoksun olmaları yapay sinir ağlarının eğitim esnasında çok büyük miktarlarda veri gereksinmesine sebep olmaktadır.

Bayram, tatil ve önemli toplumsal olayların sebep olduğu anormal günlerden elde edilen verilerin nispeten az sayıda olması, bu günlerdeki başarımının sınırlı olmasına sebep olmaktadır. Bunun yanı sıra ağın kapalı yapısı, operatörlerin tecrübe ve bilgilerinden yararlanılmasına ve anlamlı sayısal yorumları engellemektedir. Bu ve benzeri sebeplerden dolayı kısa vadeli talep tahmini için ek olarak yapay sinir ağı çıktısının, bulanık mantık uzman sistemleri tarafından düzenlendiği melez sistemler de kullanılmaktadır [35].

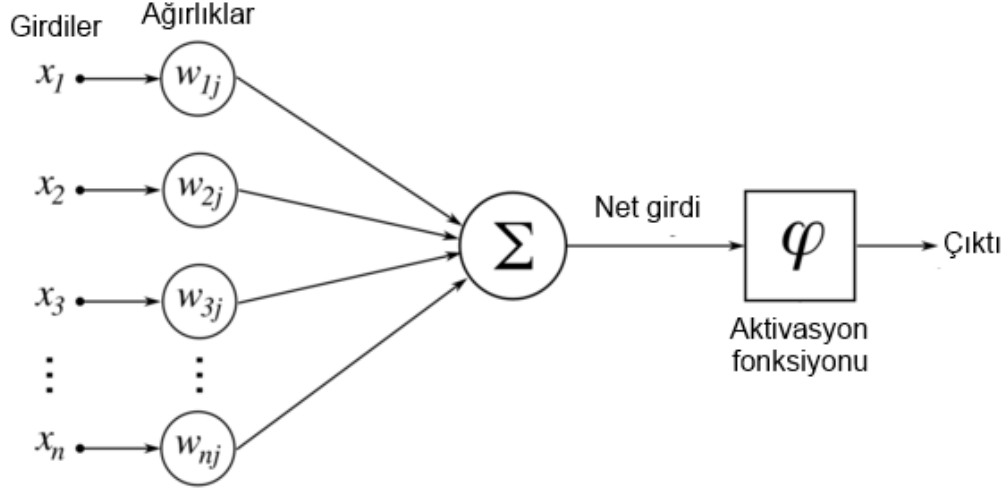
4.1.2 Yapay sinir ağlarının yapısı

Yapay sinir ağları, sinir hücrelerinden esinlenilerek tasarlanmış bir makine öğrenmesi yöntemidir. Sinir sistemi, nöron adı verilen ve bilgi işleyebilen özelleşmiş hücrelerden oluşur. Nöronlar, hücre gövdesi yanında akson ve dendrit adı verilen dışa açılan dallardan oluşmaktadır. Nöron sinirsel uyarıyı dendritleri yardımıyla alır ve ürettiği uyarıyı aksonları yardımıyla diğer hücelere iletir. Nöronların arasında sinaps adı verilen boşluklar bulunmaktadır, hücreler arası iletişim için kullanılan nöro-transmitter maddeler bu boşluklarda birikmektedir [44]. Sinapsların etkinliği zaman içinde değişebilmekte ve nöronlar bu sayede geçmiş tecrübeler ile öğrenebilmektedir. Serebral korteks 10^{11} civarında nöron içermektedir ve her nöron 10^3 - 10^4 diğer nöronla bağlıdır. Toplamda ise insan beyninde 10^{14} - 10^{15} arası nöron bağlantısı bulunmaktadır [44].



Şekil 4.1 Sinir hücresinin yapısı

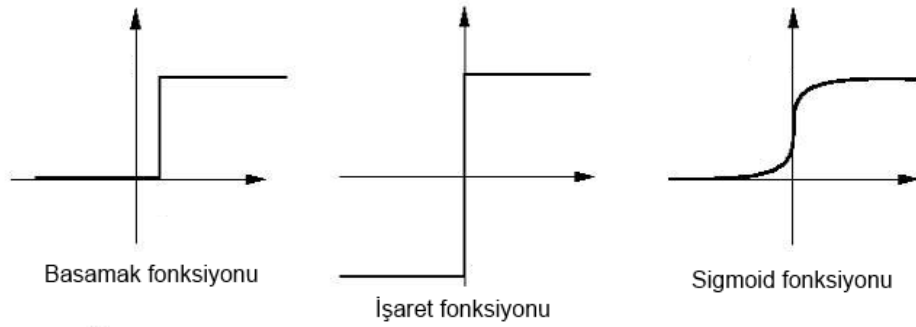
Yapay sinir ağları, insan beynini taklit etme çabası içinde ortaya atılmıştır. Nöronların matematiksel olarak basitleştirilmiş hali Şekil 4.2’de görülebilir.



Şekil 4.2 Yapay sinir hücresinin yapısı

Yapay sinir hücresinin girdileri, x_i , w_{ij} , i girdinin, j nöronun indeksi olmak üzere, ağırlığıyla çarpılarak net girdi elde edilir. Net girdi ise seçilen aktivasyon fonksiyonuna geçirilerek, nöronun nihai çıktısı elde edilir. Bu çıktı bir başka nöronun girdisi veya sinir ağının çıktısı olarak kullanılır [44].

Aktivasyon fonksiyonları problem bazında seçilir, sigmoid, basamak ve işaret fonksiyonları en çok kullanılanlardandır.



Şekil 4.3 Yapay sinir ağlarında sıkça kullanılan aktivasyon fonksiyonları


Girdisi X , ağırlık vektörü w olan yapay sinir hücresinin çıktısı Denklem 4,1'de belirtildiği şekilde olacaktır.

$$y = \varphi \left(\sum x_i * \omega_{ij} \right) \quad (4.1)$$

Yapay sinir ağı nörönların düğüm, bağlantılarının birer ayrıt olarak gösterildiği bir graf olarak ele alınabilir. Ağlar, bağlantı örüntülerine göre sınıflandırılır [44].

- İleri-besleme ağlar, herhangi bir döngü içermezler
- Özyineli ağlar, döngüler de içeren ağlardır.

İleri besleme ağlar, döngü içermediği için statiktir, belirli bir girdi için aynı çıktıyı verirler. Geri-besleme gibi algoritmalarla kolay eğitilebildikleri için oldukça sık kullanılırlar. Jain A. ve diğerlerinin çalışmasında farklı tipteki yapay sinir ağları incelenebilir [44].



Şekil 4.4 İleri besleme yapay sinir ağı yapısı

Talep tahmini için kullanılan yapay sinir ağlarında çoklukla, X, talebi etkileyen etmenler ve yakın geçmiş talep verisinden oluşturulmuş girdi vektörü olmak üzere gizli katmanda tek bir nörönun olduğu ileri besleme ağlar kullanılmaktadır.

4.2 Destek vektör makineleri

Destek vektör makineleri, orijinal ismiyle “Support Vector Machines (SVM)”, Vapnik [45] tarafından geliştirilmiş istatistiki öğrenme teorisine dayanan yeni bir metottur. Şu sıralar yapay zekâ alanında aktif bir çalışma sahası olan SVM, örüntü tanıma, fonksiyon kestirimi, sinyal işleme ve benzeri alanlarda uygulanmıştır. SVM küçük ve

doğrusal ilişkili olmayan, yüksek boyutlu veri kümelerinde büyük başarı göstermektedir.

Yapay sinir ağları istatistiki öğrenme teorisine göre, tecrübe riskini azaltmayı sağlayan empirik risk minimizasyonu ilkesine dayanmaktadır. En küçük kareler yöntemine nazaran, bu devrimsel bir başarı değildir ve teorik bir alt yapıdan, dolayısıyla kantitatif analizden yoksundur. SVM, empirik risk minimizasyonu ilkesinin yerine yapısal risk minimizasyonu ilkesini koymaktadır. Bu sayede aşırı uyum (overfitting) engellenerek yüksek genelleştirme performansı yakalanmaktadır [19].

4.2.1 Destek vektör makinelerinin yapısı

Verilmiş $(x_1, y_1), (x_2, y_2), \dots, (x_n, y_n)$ şeklindeki veri kümesi için destek vektör makineleri Denklem 4.2'yi optimize etmektedir [45].


$$\min_{\omega, b, \xi, \xi^*} \frac{1}{2} w^T w + C \sum_{i=1}^n (\xi_i \xi_i^*) \quad (4.2)$$

Bu optimizasyonda aşağıdaki Denklem 4.3'deki kısıtlar kullanılmaktadır [45].

$$\begin{aligned} y_i - (w^T \phi(x_i) + b) &\leq \varepsilon + \xi^* \\ (w^T \phi(x_i) + b) - y_i &\leq \varepsilon + \xi \\ \xi_i, \xi_i^* &\geq 0, i = 1, 2, \dots, n \end{aligned} \quad (4.3)$$

w iki hiperdüzleme dik vektör olmak üzere, $\frac{2}{|w|}$ düzlemler arası uzaklığı uzaklığı verecektir. SVM algoritması bu uzaklığı minimize eder [45]. Girdiler x_i , ϕ fonksiyonu yardımıyla yüksek boyutlu bir uzaya resmedilmiştir. ξ_i, ξ_i^* Denklem 4.4'te belirtilen ε -duyarsız tüpe bağlı kalmak koşuluyla eğitim hatasının üst ve alt limitleridir. Bu durum Şekil 4.5'te görülebilir [45].

$$|y - (w^T \phi(x) + b)| \leq \varepsilon \quad (4.4)$$



Şekil 4.5 Destek vektör makinelerinde epsilon-duyarsız tüp

Eğer x_i , belirtilen tüpün içinde kalmıyorsa ξ_i, ξ_i^* bir hata değeri alacaktır ve bu değerlerin toplamı SVM tarafından minimize edilecektir. SVM Denklem 4.5'te görülebilecek hata fonksiyonunu ve Denklem 4.6'da görülebilecek düzenleme (regularization) terimini minimize ederek ile düşük başarımlı veya aşırı uyum (overfitting) durumlarını engeller [45].

$$C \sum_{i=1}^n (\xi_i + \xi_i^*) \quad (4.5)$$

$$\frac{1}{2} w^T w \quad (4.6)$$

Klasik regresyonda ε hep sıfır kabul edilir ve veri yüksek boyutlu bir uzaya resmedilmez. Bu da SVM'in esnek bir teknik olmasının sebebidir. Φ fonksiyonu veriyi üst uzaya resmettiği için Denklem 4.2 ve Denklem 4.3'de belirtilen yerine Denklem 4.7'deki eş problem Denklem 4.8'deki kısıtlarla optimize edilebilir [45].

$$Q_{ij} = \phi(x_i)^T \phi(x_j) \quad (4.7a)$$

$$\min_{\alpha, \alpha^*} \frac{1}{2} (\alpha - \alpha^*)^T Q (\alpha - \alpha^*) + \varepsilon \sum_{i=1}^n (\alpha_i + \alpha_i^*) + \sum_{i=1}^n y_i (\alpha_i + \alpha_i^*) \quad (4.7b)$$

$$\sum_{i=1}^n (\alpha_i - \alpha_i^*) = 0 \quad (4.8)$$

$$0 \leq \alpha_i, \quad \alpha_i^* \leq C_i, \quad i = 1, 2, \dots, n$$

$\phi(x)$ 'in yüksek sayıda bileşen içermesi sebebiyle Q iç çarpımının hesap yükü yüksek olabilmektedir. Dolayısıyla çekirdek metotları, orijinal ismiyle “kernel methods” uygulanmaktadır. Çekirdek metotları, girdi verilerinin resmedildiği yüksek boyutlu uzaydaki iç çarpımı orijinal uzayda yapılabilmesine olanak sağlamaktadır [45].

Bu tez çalışmasında Denklem 4.9’da belirtilen radyal taban fonksiyonu, orijinal ismiyle “radial basis function” (RBF) çekirdek fonksiyonu kullanılmıştır.

$$\phi(x_j) = e^{-\gamma|x_1-x_2|^2} \quad (4.9)$$

RBF çekirdeği dışında çokça kullanılan çekirdek yöntemleri Denklem 4.10’da listelenmiştir.

$$\phi(x_i, x_j) = x^T x_j \quad \text{Doğrusal (4.10a)}$$

$$\phi(x_i, x_j) = (\gamma x^T x_j + r)^d, \gamma > 0 \quad \text{Polinomsal (4.10b)}$$

$$\phi(x_i, x_j) = \tanh(\gamma x^T x_j + r)^d \quad \text{Sigmoid (4.10c)}$$


4.2.2 Destek vektör makineleri parametreleri

Destek vektör makinesi paketleri Denklem 4.2’yi ikinci mertebeden programlama kullanarak hatayı global minimuma ulaştırabilmektedirler. Yani yapay sinir ağları ve benzeri modellerin aksine eğitim süreci yerel minimum değerlerde takılı kalmamakta ve kısa sürede gerçekleştirilebilmektedir [45]

Ancak, bu eğitim süreci için belirli bazı parametrelerin, veri kümesine veya çalışmaya özgü olarak kullanıcı tarafından belirlenmesi gerekmektedir. Bu parametreler, üzerinde çalışılan problemin tipine (sınıflandırma/regresyon) ve kullanılan çekirdek

yöntemine(sigmoid, RBF, doğrusal, polinomsal) göre değişmekle beraber aşağıda sıralanmıştır;

- $C > 0$ hata ceza katsayısı. Bu değer destek vektörleri hatalı sınıflandırılan veya ϵ -duyarsız tüpün dışında kalan değerler için ceza katsayısıdır. Bu değer gereğinden yüksek olması aşırı uyuma (Şekil 4.6), düşük kalması ise düşük başarıma sebep olacaktır [46].
- ϵ : ϵ -duyarsız destek vektör regresyon tüp genişliğidir. Regresyon problemlerinde tüp içerisinde kalan değerler hata olarak görülmezler. Bu değer gereğinden yüksek olması düşük başarıma, düşük kalması tüpün genişliği az olacağından dolayı aşırı uyuma (Şekil 4.6) sebep olacaktır [46].
- Seçilen çekirdek fonksiyona uygun olarak γ, r, d . Bu değerler girdi vektörleri üst uzaya resmedilirken kullanılmaktadır [46].



Şekil 4.6 Destek vektör makinesi aşırı uyum örneği

Aşırı uyum herhangi bir makine öğrenmesi metodunun eğitim kümesi dışında başarımını düşüren en önemli etmendir.

Bu çalışmada RBF çekirdek fonksiyonuyla, ϵ -duyarsız destek vektör regresyon kullanıldığı için veri setine uygun (C, γ, ϵ) değerleri bulmamız gerekti. Parametrelerin seçimi Bölüm 6.4’de detaylı olarak incelenmiştir.

4.3 Rastlantısal ormanlar

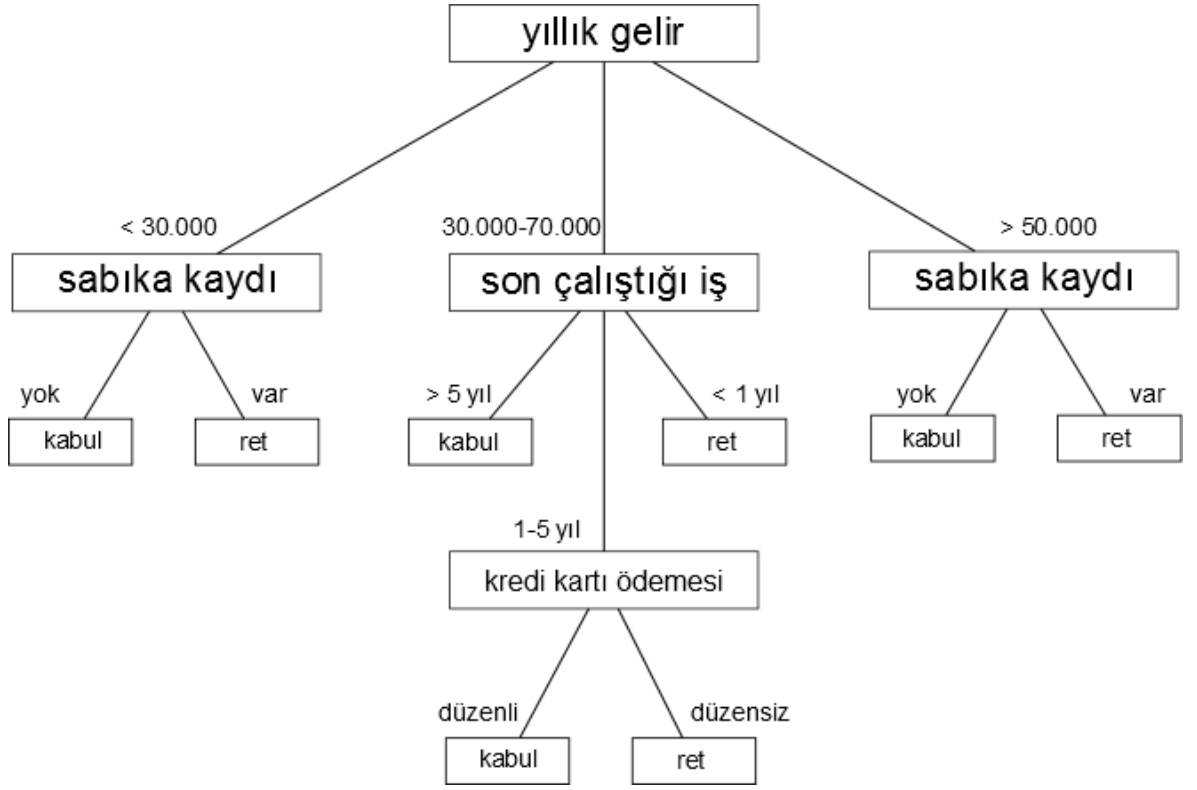
Rastlantısal ormanlar orijinal ismiyle “Random Forests”, sınıflandırma ve regresyon amacıyla kullanılan bir topluluk öğrenmesi yöntemidir [47]. Topluluk öğrenmesi, çok sayıda zayıf (düşük başarılı) öğrencinin birlikte güçlü bir model ortaya koyabilmesi esasına dayanmaktadır. Örneğin bir sınıflandırma probleminde, topluluğa sunulan yeni bir veri bütün zayıf sınıflandırıcılardan geçirilir, yeni verinin sınıfı, topluluk tarafından en çok oy alan olacaktır [48].

Rastlantısal ormanlar zayıf öğrenci olarak karar ağaçlarını kullanmaktadır. Çok sayıda ağaç, veri kümesinin rastgele seçilmiş alt kümeleri yardımıyla eğitilir. Bu alt kümeler aynı zamanda özellik bileşenlerinin de rastgele seçilmiş bir kısmını kullanmaktadır. Ağaç sayısı ve her bir ağacı eğitmek için kullanılacak özellik alt küme boyutu kullanıcı tarafından parametre olarak verilir [49].

Diğer makine öğrenmesi metotlarına göre büyük avantajlara sahiptir. Tek bir sınıflandırıcı eğitilirken küçük alt kümelerin kullanılıyor olması büyük veri kümelerinde de verimli olarak çalışabilmesini sağlamaktadır. Çapraz geçerlilik sınaması (cross-validation) algoritma dâhilinde gerçekleştirilmektedir, ağaç sayısının yüksek olması aşırı uyum (overfitting) gibi sorunlara yol açmamaktadır [49]. Her bir karar ağacı için veri kümesinin özelliklerinin sadece bir kısmının kullanılması, algoritmanın yüksek sayıda özellik içeren veri setleri için ek bir uygulama yapılmasını gereksiz kılmaktadır. Zayıf öğrencilerin eğitiminin birbirinden bağımsız yapılabilmesi ise eğitim sürecinin çok sayıda hesaplayıcı tarafından paralel olarak işletilebilmesini ve dolayısıyla ölçeklenebilirliği sağlamaktadır [49].

4.3.1 Karar ağaçları

Karar ağaçları tıp ve yöneylem araştırması gibi birçok alanda kullanılmaktadır. Karar ağaçları kısaca, eldeki bir verinin özelliklerini sırasıyla inceleyerek bir karara ulaşılmasını sağlayan kurallar bütünüdür. Örneğin bir kredi başvurusunda banka tarafından izlenebilecek örnek bir karar ağacı Şekil 4.7’deki gibi olabilir.



Şekil 4.7 Örnek banka kredi başvurusu karar ağacı

Makine öğrenmesinde kullanılan karar ağaçları kullanıcı tarafından oluşturulmazlar. Seçilen algoritma eldeki sınıflandırılmış verileri işleyerek veriye uygun karar ağacını kurar [49].

N eğitim kümesindeki elemanlarının sayısı, m ağaç başına kullanılacak özellik sayısı ya da başka bir deyişle ağacın derinliği, k ağaç sayısı, olmak üzere, rastlantısal ormanlar algoritmasındaki karar ağaçları aşağıdaki adımlarla oluşturulmaktadır [49].

1. Veri kümesinden, k ağaç sayısı defa kümenin $\frac{2}{3}$ boyutunda rastgele alt küme seçilir [47]. Bu küme seçilirken dikkat edilmesi gereken nokta, seçimlerin birbirinden bağımsız olmasıdır, seçilen bir eleman veri kümesinden çıkartılmamalıdır. Yani bir eleman aynı alt kümede birden çok sayıda bulunabilir. Bu işlem önyükleme kurgulama (bootstrap aggregating) olarak adlandırılır ve makine öğrenmesi tekniğinden bağımsız olarak başarıyı arttırabilmektedir [48].

2. Her bir ağaç üretilirken özellik vektörü bileşenleri arasından m elemanlı rastgele bir alt küme belirlenir. Yani her bir ağaç veri setinin sadece belli özellikleriyle eğitilir. Ağacın özellik alt küme elemanlarından her biri kümeyi en iyi bölecek şekilde seçilerek ağacın dalları oluşturulur [47].
3. Ağacın dalları herhangi bir şekilde budanmaz olabilecek en yüksek seviyeye getirilir [47].

Rastlantısal ormandaki ağaç sayısı yani k değeri, veri seti büyüklüğü ve performans kısıtlarına göre mümkün olan en yüksek değerde seçilebilir. Aşırı uyuma yol açmayacaktır. Ağacın derinliği -her bir ağaçta kullanılan özellik alt küme eleman sayısı- m, toplam özellik vektörü boyutundan çok daha küçük seçilmelidir. Breiman'ın bu konudaki önerisi M veri setindeki bileşen sayısı olmak üzere, $m = \frac{1}{2}\sqrt{M}$ veya $m = \sqrt{M}$ veya $m = \sqrt{M}$ şeklindedir [47].

4.4 Doğrusal regresyon

Doğrusal regresyon, bu çalışmada makine öğrenmesi tekniklerinin başarımını karşılaştırma amacıyla kullanılmıştır. Kullanılan matematiksel model oldukça basit olsa da temel bileşenler analizi tekniği ile beraber oldukça tatmin edici sonuçlar vermektedir. Kullanılan model $\omega_i \in R$ modelin katsayıları ve $x_i \in R$ talebi etkileyen etmenler ve yakın geçmişteki talep verileri olmak üzere Denklem 4.11'de görülebilir.

$$y \leftarrow \omega_0 + \omega_1 * x_1 + \omega_2 * x_2 + \dots + \omega_n * x_n \quad (4.11)$$

5 KULLANILAN DİĞER TEKNİKLER

5.1 Parçacık sürü optimizasyonu

Parçacık sürü optimizasyonu, orijinal adıyla “Particle Swarm Optimization” (PSO) türevlenebilir olması gerekmeyen herhangi bir fonksiyonu minimize/maksimize etmeyi sağlayan global optimizasyon metodudur. Rastgele seçilen bir çözümü iteratif olarak iyileştiren üst-sezgisel bir algoritmadır [50].

Kuşların davranışlarından esinlenilerek tasarlanmıştır. Tek başlarına çok temel kuralları izleyen bağımsız birimlerin, toplu halde herhangi bir merkezi koordinatör olmaksızın zeki davranışlar sergilemesi olarak adlandırılan sürü zekâsının bilgisayar bilimlerindeki uygulamalarından biridir [50].

PSO algoritması her biri parçacık olarak adlandırılan rastgele seçilmiş aday çözümlerle başlar. Sürüdeki her parçacık çözüm uzayına rastgele yerleştirilir ve her biri için rastgele hız atanır. Her iterasyonda, parçacığın konumu hızına göre, hızı ise sürüdeki en iyi aday çözümün olduğu noktaya ve kendisinin şu ana kadar bulunduğu en iyi aday çözüme uygun olarak güncellenir [51].

5.1.1 Algoritmanın adımları

$F, R_k \rightarrow R$ maksimize edilmek istenen bir fonksiyon olmak üzere, N kullanıcı tarafından seçilen sürüdeki parçacık sayısı, $x_i, v_i \in R_k$ sırasıyla i indeksli parçacığın yeri ve hızı, $p_i \in R_k$ i indeksli parçacığın geçmiş iterasyonlarında bulunduğu en uygun nokta, $g \in R_k$ tüm sürünün bulunduğu en uygun olmak üzere, parçacığın algoritmanın sözde kodu aşağıdaki gibi olacaktır [51].

- $i=1-N$ arasındaki her bir parçacık için
 - a. x_i, v_i çözüm uzayı içinde kalacak şekilde rastgele seçilir
 - b. $p_i \leftarrow x_i$
 - c. Eğer $p_i > g$ ise

$$g < -p_i$$

- Bitiş kriteri gerçekleşene kadar

- a. $i=1-N$ arasındaki her bir parçacık için
 - i. $j=1-k$ arasındaki her bir boyut için
 - ii. $r_p, r_g \in U(0,1)$ olacak şekilde rastgele iki sayı seçilir
 - iii. Parçacık hızı $d=1-k$ arasındaki her bir boyutu için güncellenir
 1. $v_{id} \leftarrow \omega v_{id} + \varphi_p r_p * (p_{id} - x_{id}) + \varphi_g r_g * (g_d - x_{id})$
 - iv. Parçacığın konumu $x_i \leftarrow x_i + v_i$ olacak şekilde güncellenir
 - v. Eğer $F(x_i) > F(p_i)$ ise
 1. $p_i \leftarrow x_i$
 2. Eğer $F(x_i) > F(g)$
 1. $g \leftarrow x_i$

- g değeri F fonksiyonunun maksimum olduğu bulunabilmiş noktada olacaktır.

$\omega, \varphi_p, \varphi_g$ parametreleri çalışmaya özel bir şekilde kullanıcı tarafından belirlenmelidir [51].

5.2 Diferansiyel evrim

Diferansiyel evrim, orijinal adıyla “differential evolution” (DE) türevlenebilir olması gerekmeyen herhangi bir fonksiyonu minimize veya maksimize etmek için kullanılan global optimizasyon yöntemidir. Var olan çözümü iteratif olarak iyileştiren bir üst-sezgisel algoritmadır. Parçacık sürü optimizasyona benzer şekilde sürü zekasını kullanır. Sürü içerisindeki her bir aday çözüm ajan, “agent” olarak adlandırılır [52].

5.2.1 Algoritma adımları

$F, R_k \rightarrow R$ maksimize edilmek istenen bir fonksiyon olmak üzere, N kullanıcı tarafından seçilen sürüdeki ajan sayısı, $x_i \in R_k$ i indeksli ajanın çözüm uzayındaki yeri olmak üzere algoritmanın sözde kodu aşağıdaki gibidir [53].

- $i=1-N$ arasındaki her bir ajan için
 - x_i çözüm uzayı içinde kalacak şekilde rastgele seçilir
- Bitiş kriteri gerçekleşene kadar
 - $i=1-N$ arasındaki her bir ajan için
 - i indeksli ajan dışında üç rastgele a, b, c ajan seçilir

- $p \in [0, k]$ olacak şekilde rastgele bir boyut seçilir
- y_i i indeksli ajanın olası yeni yeri olmak üzere
- $j=1-k$ arasındaki ajanın her bir boyutu için
 - $r \in U(0,1)$ olacak şekilde rastgele bir değer seçilir
 - Eğer $r < CR$ veya $j = p$ ise

$$y_{ij} \leftarrow a_j + D(b_j - c_j)$$
 - Değilse

$$y_{ij} \leftarrow x_{ij}$$
- Eğer $F(y_i) > F(x_i)$

$$x_i \leftarrow y_i$$
 - Ajanların içerisinde en yüksek F değeri olan seçilerek geri döndürülür.

D diferansiyel ağırlık fonksiyonu ve $CR \in U(0,1)$ krossover ihtimali olup kullanıcı tarafından seçilmelidir. Bulunan değer fonksiyonun global minimumu olacağı kesin değildir ancak pratikte oldukça yararlı olmaktadır [53].

5.3 Temel bileşenler analizi

Temel bileşenler analizi, orijinal ismiyle “Principle Component Analysis” (PCA) yüksek boyutlu veri kümelerinin, içerdikleri bilgiden minimum kayıpla düşük boyutlu uzaylara resmedilmesini sağlayan istatistik tekniğidir. Yüz tanıma, imaj sıkıştırma, nörobilim ve yapay zekâ gibi birçok alanda kullanım alanı bulmuştur [54]. PCA, araştırmacıya karmaşık bir veri setinde gizli kalabilen basit dinamiklerin ortaya çıkarılabilmesi için bir yol haritası sunar. Gürültülü ve karıştırılmış bir veri setini en anlamlı olarak tekrar ifade edebilecek bazı hali hesaplanır. Ayrıca görselleştirme lüksüne sahip olmadığımız yüksek boyutlu veriler için güçlü bir analiz aracı sağlamaktadır [55].

5.3.1 Algoritmanın adımları

Eliminizde n boyutlu m adet veri vektörünü $D_i \in R_n$ minimum kayıpla $k < n$ bir uzaya resmetmek için izlenmesi gereken adımlar aşağıdaki gibidir.

Her bir boyut için ortalamalar hesaplanır [55].

$$M_j \leftarrow \frac{1}{m} \sum_{i=1}^m D_{ij} \quad (5.1)$$

Ortalamalar boyut bazında çıkartılarak, sütun bazındaki ortalaması 0 olan, m satır ve n sütundan oluşan X_{mn} matrisi oluşturulur [55].

$$X_{ij} \leftarrow (D_{ij} - M_j) \quad (5.2)$$

X 'in sütun bazında C kovaryans matrisi hesaplanır. Sütun ortalamaları 0 olacağı için işlem Denklem 5.3'deki gibi sadeleştirilebilir [55].

$$C_{ab} \leftarrow \frac{\sum_{i=1}^m (X_{ia} X_{ib})}{m - 1} \quad (5.3)$$

C kovaryans matrisinin özdeğerleri λ_n ve özvektörleri v_n hesaplanarak, özdeğeri en küçük olan $(n - k)$ özvektör gözardı edilir. Özdeğeri en yüksek olan bileşen temel bileşen ismini almaktadır. Kalan k özvektör değerleri özellik matrisini oluşturacak şekilde sütun bazında sıralanır [55].

$$F \leftarrow [v_1, v_2, \dots, v_k] \quad (5.4)$$

Son olarak, özellik matrisi ortalanmış veri matrisi ile çarpılarak eldeki verinin az bir bilgi kaybıyla $k < n$ boyutlu uzayda yeniden ifade edilmiş haline ulaşırız [55].

$$Y_{mk} \leftarrow (F^T X^T)^T \quad (5.5)$$

Temel bileşenler analizinin gerçekleştirilmesine dair, özdeğer ve özvektörlerin hesaplanmasını da içeren, detaylar için Smith [55] ve Shlens'in [54] çalışmalarına başvurulabilir.

5.4 Mazgal taraması

Mazgal taraması, orijinal ismiyle "grid search" herhangi bir fonksiyonun parametrelerinin optimizasyonunda akla ilk gelecek, en temel yöntemdir. Her bir parametre bileşeni belirlenen alt ve üst limitler dâhilinde adımlara ayrılır ve her bir bileşenin her bir adımı denenerek en yüksek başarıyı sağlayan parametre grubu kullanılır [46].

$F, R_n \rightarrow R$ maksimize edilmek istenen bir fonksiyon, $U \in R_n$ parametrelerin üst limitleri, $L \in R_n$ param alt limitleri olmak üzere; mazgal taraması tarafından test edilecek parametre vektörlerinin kümesi T Denklem 5.6'daki Kartezyen çarpımla tanımlanır [46].

$$T = \{L_1, \dots, U_1\} \times \{L_2, \dots, U_2\} \times \dots \times \{L_n, \dots, U_n\} \quad (5.6)$$

B en iyi parametre vektörü, F fonksiyonunu en yüksek değerine ulaştıran T elemanı olarak tanımlanır [46].

$$B \leftarrow \max_{T_i} (F(T_i)) \quad (5.7)$$

6 GERÇEKLEME

6.1 Özellik vektörü seçimi

Başarılı olması beklenen bir uygulamanın Bölüm 2.3’de belirtilen etmenleri göz önünde bulundurması kaçınılmazdır.

X_n , bu etmenlerin de dâhil olduğu özellik vektörü olmak üzere, elektrik talebinin $F(X_n)$ şeklinde bir talep fonksiyonu olduğu varsayılırsa, makine öğrenmesi yöntemleri ile geçmiş tüketim verileri işlenerek $F(X_n) \sim f(X_n)$ olacak şekilde bir f temsili fonksiyonu oluşturulabilir. Bu temsili fonksiyonun başarısı gerçek verilere uygunluğu ile ölçülecektir. Hangi metot kullanılırsa kullanılsın, modelin başarısını X_n özellik vektörünün içeriği ile birebir bağıntılıdır.

Literatürdeki çalışmalarda, hava sıcaklığı, nem, basınç gibi meteorolojik etmenler özellik vektörünün en önemli bileşenlerindedir. Bunun dışında yağış, yağış tipi, rüzgar hızı gibi etmenler de eklenebilmektedir. Tablo 6.1 ‘de incelenen çalışmaların bir kısmındaki özellik vektörü bileşenleri gösterilmiştir.

Tablo 6.1 Literatürdeki çalışmalarda kullanılan özellik vektörleri

Çalışma	Özelik vektörü bileşenleri
Chen ve diğ. [17]	Haftanın günü, hissedilen sıcaklık, sıcaklık, nem, bulut örtüsü, yağış miktarı
Rahman ve Hazim [34]	Mevsim, haftanın günü, günün saati, sıcaklık, rüzgâr hızı, bulut örtüsü, nem, birikmiş ısı
Al-Hamadi ve Soliman [23]	Sıcaklık, rüzgâr hızı, nem, hissedilen sıcaklık
Osman Z. ve diğ. [39]	Rüzgâr, nem, çiy noktası, sıcaklık
Ling ve diğ. [36]	Sıcaklık, yağış
Swarup ve Satish [5]	Haftanın günü, sıcaklık
Fan ve Chen [3]	Sıcaklık, nem, rüzgâr hızı, hafta sonu olup olmaması, tatil olup olmaması
Lu ve diğ. [56]	Sıcaklık, günün saati, haftanın günü
Vermaak ve Botha [33]	Nem, yağış miktarı, rüzgâr hızı, gökyüzü durumu, mevsim
AlFuhaid ve diğ. [31]	Sıcaklık, nem
Liang ve Cheng [27]	Sıcaklık, hafta sonu olup olmaması

Meteorolojik etmenlerin temsili için “Weather Underground” şirketinden temin edilen meteorolojik veriler kullanılmıştır. Haftalık ve günlük çevrimlerin makine öğrenmesi yöntemi tarafından etkili bir şekilde tanımlanabilmesi için haftanın günü, ayın günü bileşenleri, gün uzunluğunun yıl içindeki değişiminin aydınlatma üzerindeki etkisi düşünüldüğünde; güneşin doğuşu batışı gibi astronomik faktörler de özellik vektörüne eklenmiştir. Kullanılan bileşenler aşağıda listelenmiştir.

- Ortalama, en yüksek ve en düşük sıcaklık
- Ortalama, en yüksek ve en düşük nem
- Ortalama, en yüksek ve en düşük çiy noktası
- Gün doğuşu, gün batışı ve gün uzunluğu
- Azimut, güneş-dünya uzaklığı
- Yağmur durumu ve bir önceki günün yağmur durumu
- Kar yağışı ve bir önceki gün kar yağışı
- Sis, ortalama, en düşük ve en yüksek görüş uzaklığı
- Ortalama, en yüksek ve en düşük rüzgâr hızı
- Ortalama, en yüksek ve en düşük basınç
- Gün için yaz saatinin kullanılıp kullanılmadığı
- Ayın günü, haftanın günü
- Tatil olup olmaması, bir önceki günün tatil olup olmaması

Meteorolojik verinin içerdiği gürültü ve mükerrer bilginin azaltılabilmesi için temel bileşenler analizi kullanılarak, veri daha düşük bir boyutlu bir uzaya resmedilmiştir.

Özellik vektörü bu etmenlerin yanında yakın geçmişteki talep değerlerini de içermektedir. Araştırmacı tarafından belirlenen geçmiş gün sayısı L , dış etmenler matrisi $K_{i,m}$, talep serisi Y_i olmak üzere; i indeksli gün için makine öğrenmesi metoduyla kullanılan nihai bileşen vektörü X_i Denklem 6.1’deki gibi oluşturulmaktadır.

$$X_i \leftarrow \{K_{i,1}, K_{i,2}, \dots, K_{i,m}, Y_{i-1}, Y_{i-2}, \dots, Y_{i-L}\} \quad (6.1)$$

6.2 Hata kriteri

Hata kriteri olarak EUNITE talep tahmin yarışmasında kullanılan ortalama mutlak yüzdelik hata, orijinal ismiyle "mean absolute percentage error", (MAPE) kullanılmıştır.

n , talep tahmini yapılan gün sayısı, A_i , gerçek talep değeri, F_i , tahmin edilen talep değeri olmak üzere $MAPE$, ortalama mutlak yüzdelik hata Denklem 6.2'deki gibi tanımlanmıştır.

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{A_i - F_i}{A_i} \right| \quad (6.2)$$

6.3 Geliştirme ortamı

Gerçekleme için R dili kullanılmıştır. R, istatistiki hesaplama ve grafik için ortam sunan açık kaynak kodlu bir dildir. Doğrusal, doğrusal olmayan modelleme, zaman serisi analizi, klasik istatistiki testler, sınıflandırma ve kümeleme gibi birçok problem için kolay kullanılabilir araçlar sunmaktadır. Temellerini Bell Laboratuvarlarında geliştirilen S dilinden almaktadır. Ticari bir ürün olan S diline alternatif özgür bir araçtır [57]. Geliştirme ortamı olarak "Foundation for Open Access Statistics" [58] tarafından desteklenen ve ücretsiz olarak sağlanan RStudio kullanılmıştır [59].

R, araştırmacıların kolaylıkla kullanabileceği yazılım paketlerine erişim sunmaktadır. Bu kütüphaneler, araştırmacının çalışmasını güvenilir ve hızlı bir biçimde devam ettirmesine yardımcı olacak şekilde dokümente edilmiş metotlar içermektedir.

Bu çalışmanın gerçekleştirme aşamasında R yorumlayıcısı dâhilindeki metotlar dışında aşağıdaki kütüphaneler kullanılmıştır.

- Parçacık sürü optimizasyonu için "pso - Particle Swarm Optimization, Claus Bendtsen"

- Rastlantısal ağaçların parametre seçimi için, "e1071 - Misc Functions of the Department of Statistics (e1071), TU Wien, David Meyer, Evgenia Dimitriadou, Kurt Hornik"
- Yardımcı matris fonksiyonları için "matrixStats - Methods that apply to rows and columns of a matrix, Henrik Bengtsson, Hector Corrada Bravo, Robert Gentleman, Ola Hossjer, Harris Jaffee, Peter Langfelder"
- Yapay sinir ağlarının eğitilmesi için "nnet - Feed-forward Neural Networks and Multinomial Log-Linear Models, Brian Ripley"
- Diferansiyel evrim için, "DEoptim - Global optimization by Differential Evolution, David Ardia, Katharine Mullen, Brian Peterson, and Joshua"
- Rastlantısal ormanların eğitimi için "randomForest - Breiman and Cutler's random forests for classification and regression, Andy Liaw, Matthew Wiener"

6.4 Destek vektör makineleri parametre seçimi

Bölüm 4.2.2'de belirtildiği üzere parametre seçimi destek vektör makinelerinin başarımına etki eden en önemli faktörlerden biridir. RBF çekirdeği kullanan epsilon duyarsız destek vektör makinesi regresyonu için üç parametrenin veri kümesi özelinde seçilmesi gerekmektedir. Bu parametreler, C ceza katsayısı, γ RBF çekirdeği parametresi, ε epsilon duyarsız tüp genişliğidir. Bu parametrelerin alt ve üst sınırları Hsu C. ve diğerlerinin çalışmasında Denklem 6.3'deki gibi belirlenmiştir.

$$C \in [2^{-5}, 2^{15}], \gamma \in [2^{-15}, 2^3], \varepsilon \in [2^{-8}, 2^{-1}] \quad (6.3)$$

Bu çalışmada otomatik parametre seçimi için üç farklı yöntem kullanılmıştır. Bu yöntemlerin detayları Bölüm 6.4.2'te belirtilmiştir.

6.4.1 Destek vektör makinesi parametre uyumluluğu

Seçilen bir parametrelerin, veri kümesine uyumluluğu çapraz geçerlilik sınaması (cross-validation) yöntemiyle hesaplanmıştır. Eldeki veri; eğitim, sınama ve test olacak şekilde üç kümeye ayrılır. Parametrelerle ilklendirilen destek vektör makinesi,

eđitim kümesi yardımıyla eđitilir ve sınama kümesi üzerindeki başarıyı eldeki parametrelerin uygunluk ölçütü olarak kullanılır.

V tüm veri kümesi, TR eđitim kümesi, TE test kümesi, V sınama kümesi Denklem 6.4'te tanımlanmıştır.

$$V = TR \cup V \cup TE, \quad TR \cap V \cap TE = \emptyset \quad (6.4)$$

Verilen C, γ, ϵ parametreleri için p , parametre vektörü, SVM, destek vektör makinesini verilen bir veri kümesi için eđiten fonksiyon, FORECAST, eđitilmiş bir destek vektör makinesi örneđi ile talebi tahmin eden fonksiyon, MAPE, Denklem 6.2'de belirlenen hata fonksiyonu olmak üzere; parametre uygunluk fonksiyonu FIT, Denklem 6.5'de tanımlanmıştır.

$$p_0 \leftarrow (C_0, \gamma_0, \epsilon_{s_0})$$

$$FIT(p) = -MAPE(V, FORECAST(SVM_p(TR))) \quad (6.5)$$

FIT fonksiyonunu maksimize eden parametreler, aynı zamanda test kümesi için de en uygun parametreler olduđu kabul edilmiştir. p_{best} veri kümesi için seçilen en uygun parametre olmak üzere, test kümesi ile kullanılacak destek vektör makinesi örneđi M , eđitim ve sınama kümelerinin birleşimiyle eđitilerek elde edilir.

$$M \leftarrow SVM_{p_{best}}(TR \cup V) \quad (6.6)$$

Modelin başarıyı S , test kümesindeki hata oranı ile ölçülür.

$$S \leftarrow MAPE(TE, FORECAST(M)) \quad (6.7)$$

6.4.2 Otomatik parametre seçimi

Denklem 6.5'de tanımlanan FIT maksimize edilmek istenen sıradan bir fonksiyon olarak ele alınırsa Bölüm 5.1, 5.2 ve 5.3'da detaylandırılmış global optimizasyon yöntemleri ile fonksiyonu maksimize eden -hatayı minimize eden- parametreler bulunabilir. Bunun için çalışmamızda, mazgal taraması, parçacık sürü optimizasyonu ve diferansiyel evrim olmak üzere üç yöntemi kullandık.

Hsu ve diğerklerinin alıřmalarında destek vektör makineleri parametre seiminde üstel mazgal taraması tavsiye edilmektedir. Yani C, γ, ε parametrelerinin adım kümeleri Denklem 6.4'deki gibidir.

$$\begin{aligned}C_i &\leftarrow \{2^{-15}, 2^{-14}, \dots, 2^{15}\} \\ \gamma_i &\leftarrow \{2^{-15}, 2^{-14}, \dots, 2^3\} \\ \varepsilon_i &\leftarrow \{2^{-8}, 2^{-7}, \dots, 2^1\}\end{aligned}\tag{6.4}$$

Paracık sürü optimizasyonu için "pso", diferansiyel evrim için "DEoptim", mazgal taraması için "e1071" isimli R paketleri kullanılmıřtır. Sürü zekâsı uygulamaları olan paracık sürü optimizasyonu ve diferansiyel evrim için maksimum iterasyon sayısı 250, sürü nüfusunu 80 ile sınırlandırdık.

Üst-sezgisel yöntemlerin klasik mazgal taramasına göre daha iyi sonuç verdiđi saptanmıřtır ve ilgili grafik ve veriler sonuçlar kısmında incelenebilir.

6.5 Yapay sinir ađları parametreleri

Yapay sinir ađları için klasik üç katmanlı ileri besleme yapay sinir ađları kullanılmıřtır. Saklı katmanda dört yapay nöron bulunmaktadır. Ađın eđitimi BFGS yöntemiyle metoduyla ve R kütüphanesi "nnet" yardımıyla gereklenmiřtir.

Kullanılan yapay sinir ađının parametreleri, mazgal taraması yöntemiyle optimize edilmiřtir. Parametrelerin, nihai test tarihleri dıřında kalan alt kümedeki ortalama başarımları ölçülmüş ve en yüksek olan parametre vektörü seilmiřtir. Bu hesaplama sonucunda gizli katmandaki nöron sayısı 4, ađırlık zayıflatma katsayısı (weight decay coefficient) 0.075 olarak alınmıřtır.


6.6 Rastlantısal ormanlar

Rastlantısal ormanlardaki ağaç sayısı 1000 ile sınırlanmış ve eğitimleri R kütüphanesi “e1071” yardımıyla gerçekleştirilmiştir.

7 SAYISAL SONUÇLAR

7.1 EUNITE veri kümesi


Bu veri kümesinde 1997-1998 yılına ait talepleri geliştirme ve sınav amaçıyla, 1999 yılının Ocak ayına ait talepleri ise -yarışma da olduğu gibi- test amaçıyla kullandık. Bu veri kümesinde ortalama mutlak yüzdelik % 1.65 hata oranına ulaşılmıştır.




Şekil 7.1 EUNITE veri kümesi üzerinde metotlara göre hata oranları

Tablo 7.1 EUNITE veri kümesi üzerinde metotlara göre hata oranları


Metot	En yüksek hata (%)	Ortalama hata (%)
SVR-PSO	4,756348396	1,678074524
SVR-DE	4,64692455	1,655476904
SVR-MAZGAL	6,654363139	2,44002795
YSA	8,188051321	2,45310474
RO	6,105618242	2,755567461
Doğrusal	4,572135872	2,382334576



Şekil 7.2 EUNITE veri kümesi üzerinde gerçek değerler ve SVM-PSO ile yapılan tahminler



Şekil 7.3 EUNITE veri kümesi üzerinde gerçek değerler ve SVM-DE ile yapılan tahminler




Şekil 7.4 EUNITE veri kümesi üzerinde gerçek değerler ve SVM-MAZGAL ile yapılan tahminler


Tablo 7.2 EUNITE veri kümesi üzerinde destek vektör makineleri ile yapılan tahminler

Tarih	Gerçek	SVR-PSO	HATA (%)	SVR-DE	HATA (%)	SVR-MAZGAL	HATA (%)
01.01.1999	751,00	707,83	5,75	712,90	5,07	758,88	1,05
02.01.1999	703,00	703,30	0,04	704,49	0,21	742,40	5,60
03.01.1999	677,00	683,42	0,95	679,09	0,31	694,99	2,66
04.01.1999	718,00	752,15	4,76	748,08	4,19	759,67	5,80
05.01.1999	738,00	752,14	1,92	753,27	2,07	757,02	2,58
06.01.1999	709,00	737,61	4,04	741,95	4,65	756,18	6,65
07.01.1999	745,00	757,82	1,72	755,82	1,45	781,90	4,95
08.01.1999	749,00	754,13	0,68	757,26	1,10	754,58	0,75
09.01.1999	734,00	720,44	1,85	724,03	1,36	724,86	1,25
10.01.1999	679,00	684,45	0,80	687,06	1,19	688,58	1,41
11.01.1999	748,00	756,71	1,17	760,92	1,73	768,29	2,71
12.01.1999	739,00	751,51	1,69	750,23	1,52	762,01	3,11
13.01.1999	756,00	771,31	2,03	773,09	2,26	769,98	1,85
14.01.1999	763,00	769,07	0,80	772,98	1,31	775,48	1,64
15.01.1999	752,00	751,70	0,04	759,07	0,94	759,16	0,95
16.01.1999	738,00	736,47	0,21	740,99	0,40	744,10	0,83
17.01.1999	699,00	698,92	0,01	701,60	0,37	712,47	1,93
18.01.1999	782,00	773,74	1,06	771,48	1,35	777,45	0,58
19.01.1999	782,00	777,28	0,60	778,80	0,41	786,75	0,61
20.01.1999	792,00	778,02	1,77	777,56	1,82	796,47	0,56
21.01.1999	801,00	769,86	3,89	770,96	3,75	813,98	1,62
22.01.1999	781,00	764,57	2,10	768,47	1,60	802,37	2,74
23.01.1999	731,00	743,12	1,66	740,88	1,35	772,08	5,62
24.01.1999	708,00	708,03	0,00	708,77	0,11	742,66	4,90


25.01.1999	789,00	775,17	1,75	772,41	2,10	807,28	2,32
26.01.1999	798,00	786,62	1,43	785,44	1,57	804,24	0,78
27.01.1999	791,00	791,76	0,10	790,96	0,00	796,26	0,67
28.01.1999	776,00	782,27	0,81	783,32	0,94	796,67	2,66
29.01.1999	792,00	775,00	2,15	779,60	1,57	801,62	1,22
30.01.1999	763,00	745,99	2,23	751,11	1,56	792,68	3,89
31.01.1999	743,00	712,96	4,04	720,38	3,04	756,10	1,76



Şekil 7.5 EUNITE veri kümesi üzerinde gerçek değerler ve yapay sinir ağları ile yapılan tahminler



Şekil 7.6 EUNITE veri kümesi üzerinde gerçek değerler ve rastlantısal ormanlar ile yapılan tahminler




Şekil 7.7 EUNITE veri kümesi üzerinde gerçek değerler ve doğrusal regresyon ile yapılan tahminler

Tablo 7.3 Yapay sinir ağları, rastlantısal ormanlar ve doğrusal regresyon ile yapılan tahminler

Tarih	Gerçek	YSA	HATA (%)	RO	HATA (%)	Doğrusal Reg.	HATA (%)
01.01.1999	751,00	764,87	1,85	740,54	1,39	724,85	3,48
02.01.1999	703,00	746,89	6,24	740,37	5,32	716,03	1,85
03.01.1999	677,00	695,74	2,77	712,33	5,22	676,33	0,10
04.01.1999	718,00	769,57	7,18	752,64	4,82	745,70	3,86
05.01.1999	738,00	737,11	0,12	753,09	2,05	740,69	0,36
06.01.1999	709,00	767,05	8,19	752,29	6,11	741,42	4,57
07.01.1999	745,00	790,04	6,05	753,59	1,15	753,44	1,13
08.01.1999	749,00	763,45	1,93	751,19	0,29	731,15	2,38
09.01.1999	734,00	727,42	0,90	748,84	2,02	699,04	4,76
10.01.1999	679,00	688,89	1,46	709,44	4,48	667,97	1,62
11.01.1999	748,00	776,42	3,80	757,32	1,25	736,80	1,50
12.01.1999	739,00	780,80	5,66	749,88	1,47	742,25	0,44
13.01.1999	756,00	786,80	4,07	754,91	0,14	768,32	1,63
14.01.1999	763,00	782,71	2,58	757,05	0,78	745,69	2,27
15.01.1999	752,00	767,69	2,09	752,16	0,02	733,25	2,49
16.01.1999	738,00	747,22	1,25	752,65	1,98	718,98	2,58
17.01.1999	699,00	703,10	0,59	707,49	1,22	675,42	3,37
18.01.1999	782,00	784,91	0,37	754,62	3,50	755,22	3,42
19.01.1999	782,00	785,63	0,46	761,25	2,65	746,86	4,49
20.01.1999	792,00	794,99	0,38	760,69	3,95	761,66	3,83
21.01.1999	801,00	800,10	0,11	762,11	4,85	757,89	5,38
22.01.1999	781,00	789,80	1,13	758,58	2,87	754,40	3,41
23.01.1999	731,00	768,10	5,08	754,08	3,16	729,04	0,27

24.01.1999	708,00	720,48	1,76	715,01	0,99	696,94	1,56
25.01.1999	789,00	793,31	0,55	759,74	3,71	767,84	2,68
26.01.1999	798,00	791,40	0,83	759,55	4,82	773,38	3,09
27.01.1999	791,00	791,69	0,09	755,74	4,46	769,40	2,73
28.01.1999	776,00	793,32	2,23	752,55	3,02	760,83	1,95
29.01.1999	792,00	801,22	1,16	761,86	3,81	788,26	0,47
30.01.1999	763,00	793,13	3,95	756,98	0,79	764,45	0,19
31.01.1999	743,00	752,20	1,24	719,77	3,13	728,45	1,96

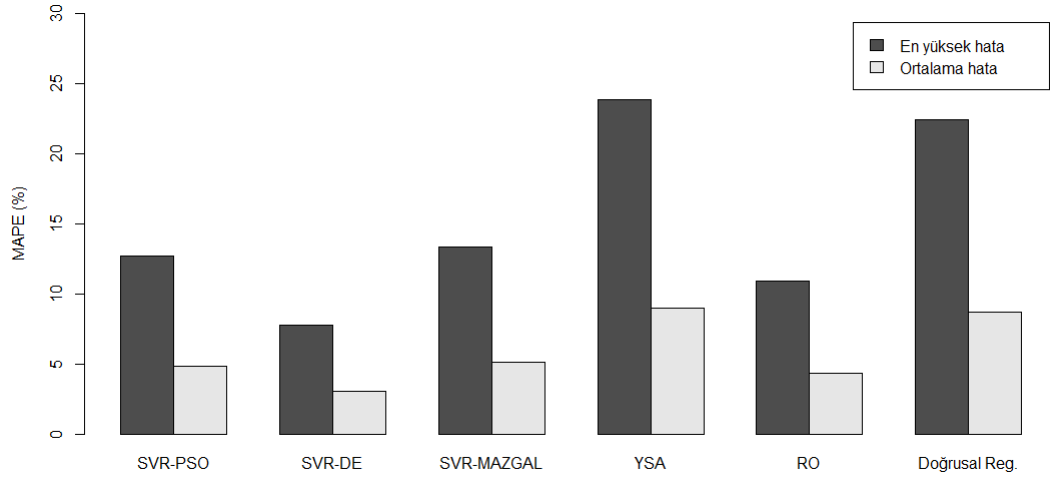
7.1.1 EUNITE veri kümesi üzerine diğer çalışmalar



Şekil 7.8 EUNITE veri kümesi üzerine literatürdeki diğer çalışmalar

7.2 Ticari işletme tüketimlerinden oluşturulan veri kümesi


Bu veri kümesinde 2013 yılının ilk 6 ayına ait talep verileri eğitim amacıyla ve Temmuz ayının verileri ise test amacıyla kullandık. Bu veri kümesinde ortalama mutlak yüzdelik %3.04 hata oranına ulaşılmıştır.




Şekil 7.9 Ticari işletme veri kümesi üzerinde metotlara göre hata oranları

Tablo 7.4 Ticari işletme veri kümesi üzerinde metotlara göre hata oranları


Metot	En yüksek hata (%)	Ortalama hata (%)
SVR-PSO	12.732405	4.807096
SVR-DE	7.733617	3.046328
SVR-MAZGAL	13.312304	5.140153
YSA	23.889391	8.955133
RO	10.913171	4.305482
Doğrusal	22.435374	8.675734



Şekil 7.10 Ticari işletme veri kümesi üzerinde gerçek değerler ve SVM-PSO ile yapılan tahminler



Şekil 7.11 Ticari işletme veri kümesi üzerinde gerçek değerler ve SVM-DE ile yapılan tahminler




Şekil 7.12 Ticari işletme veri kümesi üzerinde gerçek değerler ve SVM-MAZGAL ile yapılan tahminler


Tablo 7.5 Ticari işletme veri kümesi üzerinde destek vektör makineleri ile yapılan tahminler

Tarih	Gerçek	SVR-PSO	HATA (%)	SVR-DE	HATA (%)	SVR-MAZGAL	HATA (%)
01.06,2013	74986,11	69891,6	6,79	71829,84	4,21	68543,37	8,59
02.06,2013	57600,56	58652,27	1,83	56316,41	2,23	57369,42	0,40
03.06,2013	37827,08	40171,2	6,20	40752,48	7,73	40002,32	5,75
04.06,2013	65596,43	65199,01	0,61	65760,82	0,25	64087,56	2,30
05.06,2013	72639,46	71613,61	1,41	71693,3	1,30	70375,08	3,12
06.06,2013	71637,02	71644,27	0,01	72932,09	1,81	70429,71	1,69
07.06,2013	71398,54	72570,08	1,64	72585,68	1,66	71380,69	0,03
08.06,2013	71370,71	70009,9	1,91	71294,62	0,11	70150,31	1,71


09,06,2013	56916,92	58261,62	2,36	56985,76	0,12	58874,13	3,44
10,06,2013	38977,79	42088,67	7,98	38393,59	1,50	41005,68	5,20
11,06,2013	67753,72	66596,69	1,71	68197,63	0,66	64504,57	4,80
12,06,2013	73952,41	69042,24	6,64	71691,11	3,06	68425,71	7,47
13,06,2013	72051,54	68006,1	5,61	70145,9	2,64	67910,53	5,75
14,06,2013	73486,55	73224,12	0,36	70886,56	3,54	71721,78	2,40
15,06,2013	70639,15	69735,2	1,28	71361,67	1,02	70026,93	0,87
16,06,2013	56614,92	57822,09	2,13	58418,75	3,19	59051,21	4,30
17,06,2013	39930,66	42677,99	6,88	42838,51	7,28	41794,9	4,67
18,06,2013	69492,2	65557,46	5,66	68518,77	1,40	65095,75	6,33
19,06,2013	76898,62	70625,85	8,16	72592,06	5,60	69804,49	9,23
20,06,2013	76036,89	70366,54	7,46	73437,02	3,42	69863,63	8,12
21,06,2013	76872,69	71799,91	6,60	73999,12	3,74	71056,12	7,57
22,06,2013	74192,41	69917,28	5,76	72527,85	2,24	69589,41	6,20
23,06,2013	58938,7	59425,62	0,83	58620,12	0,54	58924,98	0,02
24,06,2013	40980,06	42858,95	4,58	42808,08	4,46	40885,29	0,23
25,06,2013	71392,69	65545,49	8,19	68623,72	3,88	64311,11	9,92
26,06,2013	78819,35	68783,75	12,73	73339,23	6,95	68326,67	13,31
27,06,2013	78949,59	71011,16	10,06	74100,3	6,14	68969,54	12,64
28,06,2013	78430,18	70898,52	9,60	74042,2	5,59	70655,92	9,91
29,06,2013	74935,22	69148,73	7,72	72378,99	3,41	68944,82	7,99
30,06,2013	60103,82	58753,71	2,25	57942,84	3,60	57770,76	3,88
01,07,2013	41446,62	43135,42	4,07	40970,49	1,15	42072,12	1,51



Şekil 7.13 Ticari işletme veri kümesi üzerinde gerçek değerler ve yapay sinir ağı ile yapılan tahminler



Şekil 7.14 Ticari işletme veri kümesi üzerinde gerçek değerler ve rastlantısal ormanlar ile yapılan tahminler



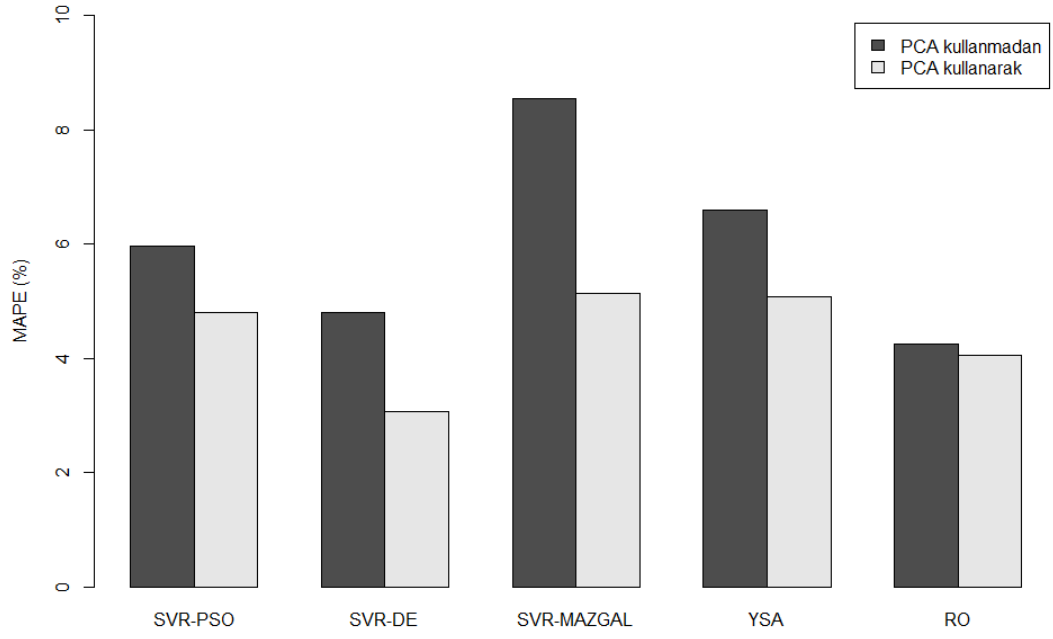
Şekil 7.15 Ticari işletme veri kümesi üzerinde gerçek değerler ve doğrusal regresyon ile yapılan tahminler

Tablo 7.6 Ticari işletme veri kümesi üzerinde yapay sinir ağları, rastlantısal ormanlar ve doğrusal regresyon ile yapılan tahminler

Tarih	Gerçek	YSA	HATA (%)	RO	HATA (%)	Doğrusal Reg,	HATA (%)
01,06,2013	74986,11	68403,47	8,78	74121,74	1,15	72664,84	3,10
02,06,2013	57600,56	50649,3	12,07	60623,26	5,25	60477,99	5,00
03,06,2013	37827,08	38665,39	2,22	41955,21	10,91	41647,85	10,10
04,06,2013	65596,43	65392	0,31	69376,4	5,76	69971,62	6,67

05,06,2013	72639,46	70047,34	3,57	70162,26	3,41	77971,26	7,34
06,06,2013	71637,02	70940,55	0,97	70553,46	1,51	77666,79	8,42
07,06,2013	71398,54	70064,44	1,87	70647,41	1,05	78059,01	9,33
08,06,2013	71370,71	68143,26	4,52	70892,34	0,67	76940,09	7,80
09,06,2013	56916,92	49803,64	12,50	60639,21	6,54	62606,65	10,00
10,06,2013	38977,79	38489,44	1,25	41247,86	5,82	43556,09	11,75
11,06,2013	67753,72	66643,88	1,64	69567,68	2,68	73257,3	8,12
12,06,2013	73952,41	69226,39	6,39	70461,92	4,72	77774,3	5,17
13,06,2013	72051,54	67247,23	6,67	69901,74	2,98	77360,15	7,37
14,06,2013	73486,55	67838,59	7,69	69578,49	5,32	78905,03	7,37
15,06,2013	70639,15	68051,71	3,66	68711,97	2,73	77593,66	9,85
16,06,2013	56614,92	49076,54	13,32	59191,26	4,55	63695,03	12,51
17,06,2013	39930,66	38556,38	3,44	39756,28	0,44	46087,32	15,42
18,06,2013	69492,2	63819,77	8,16	67742,82	2,52	75558,41	8,73
19,06,2013	76898,62	69231,71	9,97	71473,29	7,06	80757,75	5,02
20,06,2013	76036,89	69099,73	9,12	71147,56	6,43	81055,09	6,60
21,06,2013	76872,69	69078,23	10,14	71570,65	6,90	82760,44	7,66
22,06,2013	74192,41	67430,2	9,11	71709,08	3,35	80349,11	8,30
23,06,2013	58938,7	49319,6	16,32	58944,67	0,01	67469,82	14,47
24,06,2013	40980,06	38510,87	6,03	41148,59	0,41	46931,73	14,52
25,06,2013	71392,69	61636,77	13,67	68233,81	4,42	75385,56	5,59
26,06,2013	78819,35	63966,85	18,84	71575,01	9,19	80671,3	2,35
27,06,2013	78949,59	63611,8	19,43	72250,93	8,48	81734,02	3,53
28,06,2013	78430,18	65133,06	16,95	70189,88	10,51	82731,41	5,48
29,06,2013	74935,22	60982,71	18,62	70059,87	6,51	80832,72	7,87
30,06,2013	60103,82	45745,39	23,89	59530,05	0,95	66770,15	11,09
01,07,2013	41446,62	38754,3	6,50	40935,08	1,23	50745,32	22,44

7.3 Temel bileşenler analizinin hata oranına etkisi



Şekil 7.16 Temel bileşenler analizinin hata oranına etkisi

SONUÇLAR VE TARTIŞMA

Diferansiyel evrim metoduyla parametreleri seçilerek eğitilen destek vektör makinelerinin her iki veri kümesinde başarımları diğer modellerden yüksek olmuştur. Temel bileşenler analizinin ortalama hata oranlarını düşürdüğü ve meteorolojik verinin boyutunun azaltılarak başarımın arttırılabileceği tespit edilmiştir. Bu sebeplerle, temel bileşenler analizi ile birlikte parametre seçimi diferansiyel evrim metoduyla yapılan destek vektör makinelerinin bu problem için en uygun model olduğunu söyleyebiliriz. Şekil 7.8’de görülebileceği üzere bu çalışmada tavsiye edilen model, literatürde aynı veri kümesi üzerine yapılan çalışmalarla karşılaştırıldığında en yüksek sonuçlardan birini vermiştir.

Yapay sinir ağları ile de ticari olarak kullanılabilir sonuçlar elde edilmiştir. Her ne kadar oldukça sade bir model olsa da, doğrusal regresyon ile beklenilenden daha düşük hata oranlarına ulaşılmıştır.

Rastlantısal ormanlar ise bu problem için uygun bir seçim değildir. Bu metodun regresyon problemlerinde önemli bir kısıtlaması mevcuttur. Oluşturulan rastlantısal ağaçların çıktıları, eğitim kümesinin alt kümelerinin çıktılarının ortalamasından oluşmaktadır [60]. Hiçbir alt kümenin ortalamasının kümenin tümünün en düşük ve en yüksek değerleri dışına çıkamayacağından dolayı model ile yapılan tahminler, eğitim kümesinin en yüksek ve en düşük değerlerini geçememektedir. Yani yapılan talep tahminleri geçmiş tarihli taleplerin altında veya üstünde olamamaktadır. Bu durum ise Şekil 7.6’da görülebileceği gibi, tahminlerin tarihi verilerden daha yüksek veya daha küçük olmasını engellemekte ve düşük başarıma sebep olmaktadır.

Bu çalışmada kullanılan modeller, doğrusal olmayan özbağlanımlı olarak sınıflandırılabilir. Bu tip modellerin kullanımında, yapılacak her tahmin tarih aralığı için model tekrar eğitilmelidir. Tahminin yapılmaya başlanacağı tarihten önceki günler (bu çalışmada 5 ay) modelin eğitimi için kullanılır. Oluşturulan model bir ertesi günü tahmin edebilmektedir. Eğer yapılacak tahmin süresi 1 günden fazlaysa (bu çalışmada 31), yapılan tahminin gerçek değer olduğu kabul edilerek bir sonraki gün için tahmin

yapılır. Tahmin yapılan süre içerisinde gerçek veriler alındıkça, model tekrar eğitilerek ilk yapılan tahmin revize edilmelidir.

Tavsiye edilen modelin başarımının artırılması için çok farklı yöntemler denenebilir. Bunlardan ilki makine öğrenmesi modelinin çıktılarını bulanık mantık ile düzenleyen melez sistemlerdir. Literatürde yapay sinir ağları için uygulanan bu yöntemin destek vektör makineleri için de uygulanması mümkündür. Bir diğer olası eklenti ise, tahmin yapılan günlerin denetimsiz algoritmalar yardımı ile sınıflandırılarak, her bir gün sınıfı için ayrı bir modelin kullanılmasıdır. Bu yöntem ile modelin eğitimi için gereken veri miktarı artacak ancak modelin hata oranı düşecektir. Her iki yöntemin detayları ve literatürdeki uygulamaları Bölüm 3.2.2’de verilmiştir.

Talep verisini sinyal olarak ele alıp dalgacık dönüşümü gibi teknikler yardımıyla frekans bazında çalışmak olası iyileştirmelerden biri olsa da bu çalışma kapsamında kullanılan veri kümeleriyle başarılı sonuç alınamamıştır.

KAYNAKLAR

- [1] G. Gross, «Short term load forecasting,» *Proceedings of the IEEE*, cilt 75, no. 12, pp. 1558 - 1573, 1987.
- [2] A. Jain ve B. Satish, «Clustering based Short Term Load Forecasting using Support Vector Machines,» %1 içinde *PowerTech, 2009 IEEE Bucharest*, 2009.
- [3] S. Fan ve L. Chen, «Short-term load forecasting based on an adaptive hybrid method,» *Power Systems, IEEE Transactions on*, cilt 21, no. 1, pp. 392-401, 2006.
- [4] W. Charytoniuk ve M.-S. Chen, «Very short-term load forecasting using artificial neural networks,» *Power Systems, IEEE Transactions on*, cilt 15, no. 1, pp. 263-268, 2000.
- [5] K. Swarup ve B. Satish, «Integrated ANN approach to forecast load,» *Computer Applications in Power, IEEE*, cilt 15, no. 2, pp. 46-51, 2002.
- [6] N. Amjady, «Short-term hourly load forecasting using time-series modeling with peak load estimation capability,» *Power Systems, IEEE Transactions on*, cilt 16, no. 4, pp. 798-805, 2001.
- [7] S.-J. Huang ve K.-R. Shih, «Short-term load forecasting via ARMA model identification including non-Gaussian process considerations,» *Power Systems, IEEE Transactions on*, cilt 18, no. 2, pp. 673-679, 2003.
- [8] C.-M. Huang, C.-J. Huang ve M.-L. Wang, «A particle swarm optimization to identifying the ARMAX model for short-term load forecasting,» *Power Systems, IEEE Transactions on*, cilt 20, no. 2, pp. 1126-1133, 2005.
- [9] S. Michanos, A. Tsakoumis, P. Fessas, S. Vladov ve V. Mladenov, «Short-term load forecasting using a chaotic time series,» %1 içinde *Signals, Circuits and Systems, 2003. SCS 2003. International Symposium on*, 2003.
- [10] N. Sinha, L.-L. Lai, P. Ghosh ve Y. Ma, «Wavelet-GA-ANN Based Hybrid Model for Accurate Prediction of Short-Term Load Forecast,» %1 içinde *Intelligent Systems Applications to Power Systems, 2007. ISAP 2007. International Conference on*, 2007.
- [11] M. De Felice ve X. Yao, «Short-Term Load Forecasting with Neural Network Ensembles: A Comparative Study [Application Notes],» *Computational Intelligence Magazine, IEEE*, cilt 6, no. 3, pp. 47-56, 2011.
- [12] E. N. Sanchez, A. Y. Alanis ve J. Rico, «Electric load demand prediction using neural network trained by Kalman filtering,» %1 içinde *Neural Networks, 2004. Proceedings. 2004 IEEE International Joint Conference on*, 2004.
- [13] K. Liu, S. Subbarayan, R. Shoults, M. Manry, C. Kwan, F. Lewis ve J. Naccarino, «Comparison of very short-term load forecasting techniques,» *Power Systems, IEEE Transactions on*, cilt 11, no. 2, pp. 877-882, 1996.
- [14] M. Meng, J.-C. Lu ve W. Sun, «Short-Term Load Forecasting Based on Ant Colony Clustering and Improved BP Neural Networks,» %1 içinde *International Conference on Machine Learning and Cybernetics*, 2006.
- [15] H. Mori ve A. Yuihara, «Deterministic Annealing Clustering for ANN-Based Short-Term Load Forecasting,» *Power Engineering Review, IEEE*, cilt 21, no. 8, pp. 60-60, 2001.

- [16] L. M. Saini ve M. K. Soni, «Artificial Neural Network-Based Peak Load Forecasting Using Conjugate Gradient Methods,» *Power Engineering Review, IEEE*, cilt 22, no. 7, pp. 59-59, 2002.
- [17] B.-J. Chen, M.-W. Chang ve C.-J. Lin, «Load forecasting using support vector Machines: a study on EUNITE competition 2001,» *Power Systems, IEEE Transactions on*, cilt 19, no. 4, pp. 1821-1830, 2004.
- [18] S. Abbas ve M. Arif, «Electric Load Forecasting Using Support Vector Machines Optimized by Genetic Algorithm,» %1 içinde *Multitopic Conference, 2006. INMIC '06. IEEE*, 2006.
- [19] E. Elattar, J. Goulermas ve Q. Wu, «Electric Load Forecasting Based on Locally Weighted Support Vector Regression,» *Systems, Man, and Cybernetics, Part C: Applications and Reviews, IEEE Transactions on*, cilt 40, no. 4, pp. 438-447, 2010.
- [20] M.-W. Chang, B.-J. Chen ve C.-J. Jin, «EUNITE Network Competition: Electricity Load Forecasting,» National Taiwan University, Taiwan.
- [21] G.-C. Liao ve T.-P. Tsao, «Application of a fuzzy neural network combined with a chaos genetic algorithm and simulated annealing to short-term load forecasting,» *Evolutionary Computation, IEEE Transactions on*, cilt 10, no. 3, pp. 330-340, 2006.
- [22] T. Senjyu, P. Mandal, K. Uezato ve T. Funabashi, «Next day load curve forecasting using hybrid correction method,» *Power Systems, IEEE Transactions on*, cilt 20, no. 1, pp. 102-109, 2005.
- [23] H. M. Al-Hamadi ve S. A. Soliman, «Fuzzy short-term electric load forecasting using Kalman filter,» *Generation, Transmission and Distribution, IEE Proceedings-*, cilt 153, no. 2, pp. 217-227, 2006.
- [24] H. Mao, X.-J. Zeng, G. Leng, Y.-J. Zhai ve J. Keane, «Short-Term and Midterm Load Forecasting Using a Bilevel Optimization Model,» *Power Systems, IEEE Transactions on*, cilt 24, no. 2, pp. 1080-1090, 2009.
- [25] Z. Yun, Z. Quan, S. Caixin, L. Shaolan, L. Yuming ve S. Yang, «RBF Neural Network and ANFIS-Based Short-Term Load Forecasting Approach in Real-Time Price Environment,» *Power Systems, IEEE Transactions on*, cilt 23, no. 3, pp. 853-858, 2008.
- [26] K.-B. Song, Y.-S. Baek, D. H. Hong ve G. Jang, «Short-term load forecasting for the holidays using fuzzy linear regression method,» *Power Systems, IEEE Transactions on*, cilt 20, no. 1, pp. 96-101, 2005.
- [27] R.-H. Liang ve C.-C. Cheng, «Combined regression-fuzzy approach for short-term load forecasting,» *Generation, Transmission and Distribution, IEE Proceedings-*, cilt 147, no. 4, pp. 261-266, 2000.
- [28] F. Marin, F. Garcia-Lagos, G. Joya ve F. Sandoval, «Global model for short-term load forecasting using artificial neural networks,» *Generation, Transmission and Distribution, IEE Proceedings-*, cilt 149, no. 2, pp. 121-125, 2002.
- [29] L. Saini ve M. Soni, «Artificial neural network based peak load forecasting using Levenberg-Marquardt and quasi-Newton methods,» *Generation, Transmission and Distribution, IEE Proceedings-*, cilt 149, no. 5, pp. 578-584, 2002.

- [30] Z. Bashir ve M. El-Hawary, «Applying Wavelets to Short-Term Load Forecasting Using PSO-Based Neural Networks,» *Power Systems, IEEE Transactions on*, cilt 24, no. 1, pp. 20-27, 2009.
- [31] A. AlFuhaid, M. El-Sayed ve M. S. Mahmoud, «Cascaded artificial neural networks for short-term load forecasting,» *Power Systems, IEEE Transactions on*, cilt 12, no. 4, pp. 1524-1529, 1997.
- [32] Y. Chen, P. Luh, C. Guan, Y. Zhao, L. Michel, M. Coolbeth, P. Friedland ve S. Rourke, «Short-Term Load Forecasting: Similar Day-Based Wavelet Neural Networks,» *Power Systems, IEEE Transactions on*, cilt 25, no. 1, pp. 322-330, 2010.
- [33] J. Vermaak ve E. Botha, «Recurrent neural networks for short-term load forecasting,» *Power Systems, IEEE Transactions on*, cilt 13, no. 1, pp. 126-132, 1998.
- [34] S. Rahman ve O. Hazim, «A generalized knowledge-based short-term load-forecasting technique,» *Power Systems, IEEE Transactions on*, cilt 8, no. 2, pp. 508-514, 1993.
- [35] K.-H. Kim, H. sun Youn ve Y.-C. Kang, «Short-term load forecasting for special days in anomalous load conditions using neural networks and fuzzy inference method,» *Power Systems, IEEE Transactions on*, cilt 15, no. 2, pp. 559-565, 2000.
- [36] S. H. Ling, F. Leung, H. K. Lam ve P. Tam, «Short-term electric load forecasting based on a neural fuzzy network,» *Industrial Electronics, IEEE Transactions on*, cilt 50, no. 6, pp. 1305-1316, 2003.
- [37] R. Abdel-Aal, «Short-term hourly load forecasting using abductive networks,» *Power Systems, IEEE Transactions on*, cilt 19, no. 1, pp. 164-173, 2004.
- [38] I. Drezga ve S. Rahman, «Input variable selection for ANN-based short-term load forecasting,» *Power Systems, IEEE Transactions on*, cilt 13, no. 4, pp. 1238-1244, 1998.
- [39] Z. Osman, M. Awad ve T. Mahmoud, «Neural network based approach for short-term load forecasting,» %1 içinde *Power Systems Conference and Exposition, 2009. PSCE '09. IEEE/PES*, 2009.
- [40] M. guang Zhang, «Short-term load forecasting based on support vector machines regression,» %1 içinde *Machine Learning and Cybernetics, 2005. Proceedings of 2005 International Conference on*, 2005.
- [41] Y. Zhangang, C. Yanbo ve K. W. E. Cheng, «Genetic Algorithm-Based RBF Neural Network Load Forecasting Model,» %1 içinde *Power Engineering Society General Meeting, 2007. IEEE*, 2007.
- [42] A. Bakirtzis, V. Petridis, S. Kiartzis, M. Alexiadis ve A. Maassis, «A neural network short term load forecasting model for the Greek power system,» *Power Systems, IEEE Transactions on*, cilt 11, no. 2, pp. 858-863, 1996.
- [43] J. Taylor ve R. Buizza, «Neural network load forecasting with weather ensemble predictions,» *Power Systems, IEEE Transactions on*, cilt 17, no. 3, pp. 626-632, 2002.
- [44] A. Jain, J. Mao and K. M. Mohiuddin, "Artificial neural networks: a tutorial," *Computer*, vol. 3, no. 29, pp. 31-44, 1996.

- [45] V. N. Vapnik, *The nature of statistical learning theory*, New York: Springer-Verlag New York, 1995.
- [46] C.-W. Hsu, C.-C. Chang ve C.-J. Lin, «A Practical Guide to Support Vector Classification,» <http://www.csie.ntu.edu.tw/~cjlin>, Taipei, 2010.
- [47] L. Breiman, «Random Forests,» *Machine Learning*, no. 45 , pp. 5-32, 2001.
- [48] L. Breiman, «Bagging Predictors,» *Machine Learning*, no. 24, pp. 123-140, 1996.
- [49] A. Cutler ve L. Breiman, «Random Forests,» [Çevrimiçi]. Available: http://www.stat.berkeley.edu/~breiman/RandomForests/cc_home.htm.
- [50] J. Kennedy ve R. Eberhart, %1 içinde *Encyclopedia of Machine Learning*, Springer, 2010, pp. 1942-1948.
- [51] M. E. H. Pedersen ve A. J. Chipper, «Simplifying Particle Swarm Optimization,» *Applied Soft Computing*, 2009.
- [52] R. Storn ve K. Price, «Differential Evolution - A simple and efficient adaptive scheme for global optimization over continuous spaces,» *Journal of Global Optimization*, cilt 11, no. 4, pp. 341-359, 1997.
- [53] V. Arunachalam, «Optimization Using Differential Evolution,» %1 içinde *Water Resources Research Report Book 22*, The University of Western Ontario, 2008.
- [54] J. Shlens, «A Tutorial on Principal Component Analysis, Derivation, Discussion and Singular Value Decomposition,» [ucsd.edu](http://www.ucsd.edu), 2003.
- [55] L. I. Smith, «A tutorial on Principal Components Analysis,» 2002.
- [56] C. Lu, H.-T. Wu ve S. Vemuri, «Neural network based short term load forecasting,» *Power Systems*, cilt 8, no. 1, pp. 336,342, 1993.
- [57] «The R Project for Statistical Computing,» [Çevrimiçi]. Available: <http://www.r-project.org/>.
- [58] «Foundation for open access statistics,» [Çevrimiçi]. Available: <http://www.foastat.org/>.
- [59] «Software, education, and services for the R community,» [Çevrimiçi]. Available: <http://www.rstudio.com/>.
- [60] A. Liaw ve M. Wiener, «Classification and regression by randomForest,» *R news*, cilt 2, no. 3, pp. 18-22, 2002.
- [61] J. Taylor, «Short-Term Load Forecasting With Exponentially Weighted Methods,» *Power Systems, IEEE Transactions on*, cilt 27, no. 1, pp. 458-464, 2012.
- [62] Y. Chakhchoukh, P. Panciatici ve L. Mili, «Electric Load Forecasting Based on Statistical Robust Methods,» *Power Systems, IEEE Transactions on*, cilt 26, no. 3, pp. 982-991, 2011.
- [63] Y.-S. Huang ve J.-J. Deng, «Short-Term Load Forecasting Based on Ant Colony Fuzzy Clustering and SVM Algorithm,» %1 içinde *Natural Computation, 2008. ICNC '08. Fourth International Conference on*, 2008.
- [64] V. Ferreira ve A. Alves da Silva, «Toward Estimating Autonomous Neural Network-Based Electric Load Forecasters,» *Power Systems, IEEE Transactions on*, cilt 22, no. 4, pp. 1554-1562, 2007.
- [65] T. Niimura, «Forecasting techniques for deregulated electricity market prices,» %1 içinde *Power Engineering Society General Meeting, 2006. IEEE*, 2006.

- [66] K. Methaprayoon, W.-J. Lee, P. Didsayabutra, J. Liao ve R. Ross, «Neural network-based short term load forecasting for unit commitment scheduling,» içinde *Industrial and Commercial Power Systems, 2003. 2003 IEEE Technical Conference*, 2003.
- [67] S. Ling, F. H. F. Leung, H. Lam, Y.-S. Lee ve P.-S. Tam, «A novel genetic-algorithm-based neural network for short-term load forecasting,» *Industrial Electronics, IEEE Transactions on*, cilt 50, no. 4, pp. 793-799, 2003.

ÖZGEÇMİŞ

1983 yılında Bursa'da doğdu. İlk ve orta öğrenimini Bursa'da tamamladı. 2003 yılında İstanbul Kültür Üniversitesi Matematik-Bilgisayar bölümünü burslu olarak kazandı.

2007-2011 yılları arasında yazılım geliştirme uzmanı olarak Adeko Grup Bilişim'de çalıştı. 2010 yılında İstanbul Kültür Üniversitesi Bilgisayar Mühendisliği programına kabul edildi. 2011 yılından bu yana Alcatel-Lucent Teletaş'da yazılım mühendisi olarak çalışmakta ve lisansüstü eğitimine devam etmektedir.