

**T.C.
YILDIZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

**OPERASYON İŞLEMLERİNİN HIZLANDIRILMASINDA VERİ
MADENCİLİĞİNİN KULLANILMASI**

SEYHAN AMASYALI

**YÜKSEK LİSANS TEZİ
BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI**

**DANIŞMAN
YRD. DOÇ. DR. BANU DİRİ**

İSTANBUL, 2011

**T.C.
YILDIZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

**OPERASYON İŞLEMLERİNİN HIZLANDIRILMASINDA VERİ
MADENCİLİĞİNİN KULLANILMASI**

SEYHAN AMASYALI

**YÜKSEK LİSANS TEZİ
BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI**

**DANIŞMAN
DOÇ. DR. BANU DİRİ**

İSTANBUL, 2011

T.C.
YILDIZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

OPERASYON İŞLEMLERİNİN HIZLANDIRILMASINDA VERİ
MADENCİLİĞİNİN KULLANILMASI

Seyhan AMASYALI tarafından hazırlanan tez çalışması 26.04.2011 tarihinde aşağıdaki jüri tarafından Yıldız Teknik Üniversitesi Fen Bilimleri Enstitüsü Bilgisayar Mühendisliği Anabilim Dalı'nda **YÜKSEK LİSANS TEZİ** olarak kabul edilmiştir.

Tez Danışmanı

Yrd. Doç. Dr. Banu DİRİ
Yıldız Teknik Üniversitesi

Jüri Üyeleri

Prof. Dr. Nizamettin AYDIN
Yıldız Teknik Üniversitesi

Yrd. Doç. Dr. Seher BAŞLIK
Mimar Sinan Üniversitesi

ÖNSÖZ

İşletmelerin iş süreçlerinden temin ettikleri verileri karar verme aşamasında bilgiye dönüştürme işi her geçen gün önem kazanmaktadır. Zaman serisi analiziyle, geçmiş dönemlere ilişkin gözlem değerleri kullanılarak geçmişi açıklama ve geleceğe dönük tahminler yapma mümkün hale gelmiştir. Böylece elde edilecek tahminler gerek ülke ekonomisi gerekse işletme temelinde yapılacak geleceğe dönük planlama işlerini kolaylaştıracaktır. Bu çalışmada büyük bir bankanın operasyon süreçlerine ait tahmin modelleri oluşturulmuş, böylece kaynak planlamasının etkin bir şekilde yapılabilmesi ve işlemlerin hızlandırılması mümkün hale gelmiştir.

Çalışmam boyunca yardım ve desteğini esirgemeyen, her zaman motive edici eleştirileri ile bana yön veren danışman hocam Sayın Yrd. Doç. Dr. Banu DİRİ'ye ve çalışmam için veriyi sağlayan bankanın iş akış ve doküman yönetimi grubuna teşekkür ederim.

Tezimin her aşamasında beni yüreklendiren, destekleyen, bilgisiyle katkıda bulunan sevgili eşim M. Fatih AMASYALI'ya ve en kötü anlarda bile müthiş mizah yeteneği ile beni güldürmeyi başaran sevgili arkadaşım Zehra ATAY'a; verdikleri destek ve moral için sonsuz teşekkürlerimi sunarım. İyi ki varsınız...

Bu günlere gelmemde büyük pay sahibi olan sevgili aileme, dostlarıma, hocalarıma teşekkür ederim. Tezimi, kısa zaman önce kaybettiğim rahmetli babam Ali Yaşar İŞLER'e ithaf ediyorum.

Nisan, 2011

Seyhan AMASYALI

İÇİNDEKİLER

	Sayfa
SİMGE LİSTESİ.....	viii
KISALTMA LİSTESİ.....	x
ŞEKİL LİSTESİ.....	xi
ÇİZELGE LİSTESİ	xiii
ÖZET	xv
ABSTRACT	xvii
BÖLÜM 1	
GİRİŞ	1
1.1 Literatür Özeti	1
1.2 Tezin Amacı.....	4
1.3 Hipotez.....	5
BÖLÜM 2	
ZAMAN SERİLERİ.....	7
2.1 Zaman Serilerinin Bileşenleri	8
2.1.1 Trend Bileşeni	8
2.1.2 Mevsimsel Bileşen.....	8
2.1.3 Konjonktürel Bileşen	9
2.1.4 Rassal Bileşen.....	10
BÖLÜM 3	
VERİ TOPLAMA VE ÖN İŞLEME.....	11
3.1 Veri Toplama.....	11
3.2 Veri Ön İşlemleri.....	15
3.3 İşlem Tipleri İçin Geçmiş Gün Korelasyonlarının Analizi	18

BÖLÜM 4

KULLANILAN ALGORİTMALAR	23
4.1 Zaman Serisi Algoritmaları.....	24
4.1.1 Ekonometrik Modeller	24
4.1.2 Elman Ağ	26
4.1.3 Markov Rejim Değişim Modeli.....	27
4.2 Makine Öğrenmesi Algoritmaları.....	28
4.2.1 Zero Rule.....	29
4.2.2 M5 Kuralları (M5 Rules).....	29
4.2.3 Karar Tablosu (Decision Table)	30
4.2.4 Birleşik Kural (Conjunctive Rule).....	30
4.2.5 REP Ağacı (REP Tree)	31
4.2.6 Gauss Süreçleri (Gaussian Processes)	32
4.2.7 Eş Aralıklı Regresyon (Isotonic Regression).....	33
4.2.8 Doğrusal Regresyon (Linear Regression).....	33
4.2.9 Yapay Sinir Ağı (Multilayer Perceptron)	33
4.2.10 Basit Doğrusal Regresyon (Simple Linear Regression).....	35
4.2.11 Karar Destek Vektörleriyle Regresyon (SMO Regression).....	36
4.2.12 Örnek Tabanlı Algoritmalar (Ibk ve KStar)	36
4.2.13 Toplamsal Regresyon (Additive Regression)	37
4.2.14 Torbalama (Bagging)	39

BÖLÜM 5

UYGULAMA SONUÇLARI	40
5.1 Klasik Zaman Serisi Algoritmaları Kullanılarak Elde Edilen Sonuçlar	40
5.1.1 Ekonometrik Modeller Kullanılarak Elde Edilen Sonuçlar	40
5.1.2 Elman Ağ Kullanılarak Elde Edilen Sonuçlar	41
5.1.3 Markov Saklı Rejim Modeli Kullanılarak Elde Edilen Sonuçlar	42
5.2 Makine Öğrenmesi Algoritmaları Kullanılarak Elde Edilen Sonuçlar	43
5.2.1 Giriş Verisinin İfade Edilme Türleri.....	44
5.2.2 Denenecek Senaryoların Oluşturulma Adımları	46
5.2.3 EFTOD İşlem Tipi İçin Tahminde Kullanılacak Makine Öğrenmesi Modelinin (Senaryo-Algoritma İkili) Belirlenmesi	50
5.2.4 FAHES İşlem Tipi İçin Tahminde Kullanılacak Makine Öğrenmesi Modelinin (Senaryo-Algoritma İkili) Belirlenmesi	53
5.2.5 FHEFT İşlem Tipi İçin Tahminde Kullanılacak Makine Öğrenmesi Modelinin (Senaryo-Algoritma İkili) Belirlenmesi	58
5.2.6 FHVRH İşlem Tipi İçin Tahminde Kullanılacak Makine Öğrenmesi Modelinin (Senaryo-Algoritma İkili) Belirlenmesi	61
5.2.7 GUMVR İşlem Tipi İçin Tahminde Kullanılacak Makine Öğrenmesi Modelinin (Senaryo-Algoritma İkili) Belirlenmesi	65
5.2.8 HABRM İşlem Tipi İçin Tahminde Kullanılacak Makine Öğrenmesi Modelinin (Senaryo-Algoritma İkili) Belirlenmesi	69

5.2.9	HVALE İşlem Tipi İçin Tahminde Kullanılacak Makine Öğrenmesi Modelinin (Senaryo-Algoritma İkili) Belirlenmesi	74
5.2.10	MAASO İşlem Tipi İçin Tahminde Kullanılacak Makine Öğrenmesi Modelinin (Senaryo-Algoritma İkili) Belirlenmesi	77
5.2.11	REZVM İşlem Tipi İçin Tahminde Kullanılacak Makine Öğrenmesi Modelinin (Senaryo-Algoritma İkili) Belirlenmesi	81
5.2.12	SSKTA İşlem Tipi İçin Tahminde Kullanılacak Makine Öğrenmesi Modelinin (Senaryo-Algoritma İkili) Belirlenmesi	86
5.2.13	VERGI İşlem Tipi İçin Tahminde Kullanılacak Makine Öğrenmesi Modelinin (Senaryo-Algoritma İkili) Belirlenmesi	89
5.2.14	VRMAN İşlem Tipi İçin Tahminde Kullanılacak Makine Öğrenmesi Modelinin (Senaryo-Algoritma İkili) Belirlenmesi	92
5.2.15	YDFON İşlem Tipi İçin Tahminde Kullanılacak Makine Öğrenmesi Modelinin (Senaryo-Algoritma İkili) Belirlenmesi	97
5.2.16	İşlem Tiplerinin İlişkisinin İncelenmesi ve Bu Bilginin Tahmin İşleminde Kullanılması	101
5.2.17	Makine Öğrenmesi Algoritmalarının Genel Değerlendirilmesi.....	104
5.3	Genel Değerlendirme	111

BÖLÜM 6

SONUÇ VE ÖNERİLER	114
-------------------------	-----

KAYNAKLAR.....	118
----------------	-----

EK-A

EKONOMETRİK MODELLER (AR, MA, ARIMA) KULLANILARAK ELDE EDİLEN

SONUÇLAR	122
----------------	-----

EK-B

ELMAN AĞ KULLANILARAK ELDE EDİLEN SONUÇLAR.....	126
---	-----

EK-C

MARKOV SAKLI REJİM MODELİ KULLANILARAK ELDE EDİLEN SONUÇLAR.....	128
--	-----

EK-D

EFTOD İŞLEM TİPİ İÇİN 1. ADIM SONUÇLARI	130
---	-----

EK-E

FAHES İŞLEM TİPİ İÇİN 1. ADIM SONUÇLARI.....	132
--	-----

EK-F

FHEFT İŞLEM TİPİ İÇİN 1. ADIM SONUÇLARI	134
---	-----

EK-G

FHVRH İŞLEM TİPİ İÇİN 1. ADIM SONUÇLARI	136
EK-H	
GUMVR İŞLEM TİPİ İÇİN 1. ADIM SONUÇLARI	138
EK-I	
HABRM İŞLEM TİPİ İÇİN 1. ADIM SONUÇLARI.....	140
EK-İ	
HVALE İŞLEM TİPİ İÇİN 1. ADIM SONUÇLARI	142
EK-J	
MAASO İŞLEM TİPİ İÇİN 1. ADIM SONUÇLARI.....	144
EK-K	
REZVM İŞLEM TİPİ İÇİN 1. ADIM SONUÇLARI	146
EK-L	
SSKTA İŞLEM TİPİ İÇİN 1. ADIM SONUÇLARI	148
EK-M	
VERGİ İŞLEM TİPİ İÇİN 1. ADIM SONUÇLARI	150
EK-N	
VRMAN İŞLEM TİPİ İÇİN 1. ADIM SONUÇLARI	152
EK-O	
YDFON İŞLEM TİPİ İÇİN 1. ADIM SONUÇLARI.....	154
EK- Ö	
SENARYOLARIN HER BİR İŞLEM TİPİNDE KAÇINCI OLDUĞU VE ORTALAMASI BİLGİSİ..	156
ÖZGEÇMİŞ	160

SİMGE LİSTESİ

a_i	Yapay Sinir Ağındaki saklı katmanın i. nöronunun çıkışı
a_j	Yapay Sinir Ağındaki j. çıkış nöronunun mevcut çıkışı
$AR(p)$	p. dereceden otoregresif model
$ARIMA(p,q,d)$	d. dereceden farkı alınmış; p. dereceden otoregresif model ile q. dereceden hareketli ortalama model içeren model
d_j	Yapay Sinir Ağındaki j. çıkış nöronunun eğitim etiketlerine göre olması gereken değeri
E_i	Yapay Sinir Ağındaki saklı katmanın i. nöronunun hatası
E_j	Yapay Sinir Ağındaki çıkış katmanının j. nöronunun hatası
$e_t, e_{t-1}, e_{t-2}, \dots, e_{t-q}$	Zamana bağlı hata terimleri
H	Gauss Süreçleri algoritmasındaki kernel fonksiyonu sayısı
$H(x_j)$	Toplamsal Regresyon algoritmasındaki j. örneğin H regresörüne göre çıkışı
K	Lineer regresyon modelindeki parametre sayısı
$ K $	K kümesinin eleman sayısı
L	Toplamsal Regresyon algoritmasında komitedeki regresör sayısı
M	Yapay Sinir Ağındaki momentum katsayısı
$MA(q)$	q. dereceden hareketli ortalama modeli
N	Örnek sayısı
N_t	Yapay Sinir Ağında t. andaki öğrenme katsayısı
RSS	Karesel hataların toplamı
$sd(K)$	K değerlerinin standart sapması
$SKN\#$	Saklı katmandaki nöron sayısı
Sw	Toplamsal Regresyon algoritmasındaki örneklerin eğitim kümesine seçilme ağırlıkları
T	Eğitim örneklerinin sayısı
T_i	i. örneğin tahmin değeri
W	Gauss Süreçleri algoritmasındaki fonksiyonların ağırlıkları
w_0	Basit Doğrusal Regresyon algoritmasındaki bias değeri
w_{ij}	Yapay Sinir Ağındaki j. nöronla bir önceki katmandaki i. nöron arasındaki bağlantının ağırlığı
X_i	X veri kümesinin i. özelliklerinin değerleri

X_i^+	X veri kümesinin i. özelliği θ eşik değerinden büyük olanlarının değerleri
X_i^-	X veri kümesinin i. özelliği θ eşik değerinden küçük olanlarının değerleri
$x_t, x_{t-1}, x_{t-2}, \dots, x_{t-p}$	Geçmiş gözlem değerleri
y_i	i. örneğin gerçek çıkış değeri
y_{gercek}^j	j. eğitim örneğinin çıkış değeri
Z_i	Toplamsal Regresyon algoritmasındaki normalizasyon katsayısıdır
E	Rassal şoklar
α_i	Toplamsal Regresyon algoritmasındaki regresörlerin önem dereceleri
$\phi_1, \phi_2, \dots, \phi_p$	AR (otoregresif) modelin çıkış parametreleri
$\phi(x)$	Gauss Süreçleri algoritmasında giriş verisi üzerinde tanımlı bir kernel fonksiyonu
$\theta_1, \theta_2, \dots, \theta_q$	MA (hareketli ortalama) modelin çıkış parametreleri
λ	Gauss Süreçleri algoritmasındaki regularizasyon parametresi

KISALTMA LİSTESİ

AR	Otoregresif model
ARIMA	Otoregresif Hareketli Ortalama modeli
EFTOD	EFT işlemi
FAHES	Toplu hesap işlemi
FHEFT	Toplu EFT işlemi
FHVRH	Virman işlemi
GUMVR	Gümrük vergisi tahsilatı
HABRM	Yanlış işlem tipi bildirimi
HVALE	Havale işlemi
MA	Hareketli ortalama modeli
MAASO	Maaş ödemesi
MLP	Çok Katmanlı Algılayıcı
MS-VAR	Markov Rejim Değişim – Vektör Oto Regresif modeli
RBF	Radyal Tabanlı Fonksiyon
REZVM	Rezerv mevduatı
KHKK	Ortalama karesel hatanın karekökü
SSKTA	SSK tahsilatı
SVM	Destek Vektör Makinesi
VERGI	Vergi tahsilatı
VRMAN	Virman işlemi
YDFON	Yurt dışı çıkış fonu

ŞEKİL LİSTESİ

	Sayfa
Şekil 1.1 Operasyon merkezinin genel çalışma şekli.....	5
Şekil 2.1 Örnek bir zaman serisinin kartezyen grafiği	9
Şekil 3.1 EFTOD işlem tipine (eft işlemine) ait günlük adetler	12
Şekil 3.2 FAHES işlem tipine (toplu hesap işlemine) ait günlük adetler	12
Şekil 3.3 FHEFT işlem tipine (toplu eft işlemine) ait günlük adetler	12
Şekil 3.4 FHVRH işlem tipine (virman işlemine) ait günlük adetler	13
Şekil 3.5 GUMVR işlem tipine (gümrük vergisi tahsilat işlemine) ait günlük adetler	13
Şekil 3.6 HABRM işlem tipine (yanlış işlem tipi bildirim işlemine) ait günlük adetler	13
Şekil 3.7 HVALE işlem tipine (havale işlemine) ait günlük adetler	13
Şekil 3.8 MAASO işlem tipine (maaş ödemesi işlemine) ait günlük adetler	14
Şekil 3.9 REZVM işlem tipine (rezerv mevduat işlemine) ait günlük adetler	14
Şekil 3.10 SSKTA işlem tipine (SSK tahsilat işlemine) ait günlük adetler	14
Şekil 3.11 VERGI işlem tipine (vergi tahsilat işlemine) ait günlük adetler	14
Şekil 3.12 VRMAN işlem tipine (virman işlemine) ait günlük adetler	15
Şekil 3.13 YDFON işlem tipine (yurt dışı çıkış fonu işlemine) ait günlük adetler	15
Şekil 3.14 EFTOD - resmi tatil ve aykırı nokta normalizasyonu	15
Şekil 3.15 FAHES - resmi tatil ve aykırı nokta normalizasyonu	15
Şekil 3.16 FHEFT - resmi tatil ve aykırı nokta normalizasyonu	15
Şekil 3.17 FHVRH - resmi tatil ve aykırı nokta normalizasyonu	15
Şekil 3.18 GUMVR - resmi tatil ve aykırı nokta normalizasyonu	15
Şekil 3.19 HABRM - resmi tatil ve aykırı nokta normalizasyonu	15
Şekil 3.20 HVALE - resmi tatil ve aykırı nokta normalizasyonu	15
Şekil 3.21 MAASO - resmi tatil ve aykırı nokta normalizasyonu	15
Şekil 3.22 REZVM - resmi tatil ve aykırı nokta normalizasyonu	15
Şekil 3.23 SSKTA - resmi tatil ve aykırı nokta normalizasyonu	15
Şekil 3.24 VERGI - resmi tatil ve aykırı nokta normalizasyonu	15
Şekil 3.25 VRMAN - resmi tatil ve aykırı nokta normalizasyonu	15
Şekil 3.26 YDFON - resmi tatil ve aykırı nokta normalizasyonu	18
Şekil 3.27 EFTOD - 60 günlük geçmiş gün korelasyonu	18
Şekil 3.28 FAHES - 60 günlük geçmiş gün korelasyonu	18
Şekil 3.29 FHEFT - 60 günlük geçmiş gün korelasyonu	18
Şekil 3.30 FHVRH - 60 günlük geçmiş gün korelasyonu	18
Şekil 3.31 GUMVR - 60 günlük geçmiş gün korelasyonu	18
Şekil 3.32 HABRM - 60 günlük geçmiş gün korelasyonu	18

Şekil 3.33	HVALE - 60 günlük geçmiş gün korelasyonu.....	20
Şekil 3.34	MAASO - 60 günlük geçmiş gün korelasyonu.....	20
Şekil 3.35	REZVM - 60 günlük geçmiş gün korelasyonu.....	20
Şekil 3.36	SSKTA - 60 günlük geçmiş gün korelasyonu	20
Şekil 3.37	VERGI - 60 günlük geçmiş gün korelasyonu	21
Şekil 3.38	VRMAN - 60 günlük geçmiş gün korelasyonu.....	21
Şekil 3.39	YDFON – 60 günlük geçmiş gün korelasyonu	21
Şekil 4.1	Zaman serisinin bir makine öğrenmesi algoritmasına giriş örneği	23
Şekil 4.2	Elman ağ yapısı [26]	26
Şekil 4.3	Zaman içinde sadece biri aktif olan iki dağılımdan elde edilen gözlemler (Zucchini ve MacDonald [27]).....	27
Şekil 4.4	Dağılımın zaman içinde aktif olma olasılıkları [28]	28
Şekil 4.5	Örnek bir M5 model ağacının alt uzay sınırları [31].....	30
Şekil 4.6	Örnek bir M5 model ağacı [31]	30
Şekil 4.7	Örnek birçok katmanlı algılayıcı.....	34
Şekil 5.1	Senaryo üretici .NET programı.....	46
Şekil 5.2	Her bir işlem tipinin, diğer işlem tiplerine ait 1 gün önceki geçmiş veri ile korelasyonu.....	101
Şekil 5.3	REZVM işlem tipinin GUMVR işlem tipine etkisi.....	102
Şekil 5.4	GUMVR işlem tipinin REZVM'ye etkisi	103
Şekil 5.5	FHVRH ve FHEFT işlem tiplerinin VRMAN'e etkisi	103
Şekil 5.6	Makine öğrenmesi algoritmalarının performansları.....	106
Şekil 5.7	Makine öğrenmesi algoritmalarının ortalama ve standart sapma bilgisi ..	106
Şekil 5.8	EFTOD - gerçek değer, tahmin ve bunların arasındaki fark (hata).....	106
Şekil 5.9	FAHES - gerçek değer, tahmin ve bunların arasındaki fark (hata)	106
Şekil 5.10	FHEFT - gerçek değer, tahmin ve bunların arasındaki fark (hata)	106
Şekil 5.11	FHVRH - gerçek değer, tahmin ve bunların arasındaki fark (hata)	106
Şekil 5.12	GUMVR - gerçek değer, tahmin ve bunların arasındaki fark (hata)	106
Şekil 5.13	HABRM - gerçek değer, tahmin ve bunların arasındaki fark (hata).....	106
Şekil 5.14	HVALE - gerçek değer, tahmin ve bunların arasındaki fark (hata).....	106
Şekil 5.15	MAASO - gerçek değer, tahmin ve bunların arasındaki fark (hata).....	106
Şekil 5.16	REZVM - gerçek değer, tahmin ve bunların arasındaki fark (hata).....	106
Şekil 5.17	SSKTA - gerçek değer, tahmin ve bunların arasındaki fark (hata)	106
Şekil 5.18	VERGI - gerçek değer, tahmin ve bunların arasındaki fark (hata)	106
Şekil 5.19	VRMAN - gerçek değer, tahmin ve bunların arasındaki fark (hata).....	106
Şekil 5.20	YDFON - gerçek değer, tahmin ve bunların arasındaki fark (hata)	110

ÇİZELGE LİSTESİ

	Sayfa
Çizelge 4.1 Farklı hata eşikleri için oluşturulmuş regresyon ağaçları ve çıkışları [34]	41
Çizelge 5.1 Her bir işlem tipi için en iyi tahmini veren ekonometrik modeller	41
Çizelge 5.2 Her bir işlem tipi için en iyi tahmini veren Elman Ağ parametreleri	42
Çizelge 5.3 Her bir işlem tipi için en iyi tahmini veren Markov Saklı Rejim Modelinin parametreleri	43
Çizelge 5.4 Kullanılan makine öğrenmesi algoritmaları	44
Çizelge 5.5 1.adımda oluşturulan senaryolar	47
Çizelge 5.6 Senaryo oluşturma 3.adım zaman farkı seçenekleri	49
Çizelge 5.7 EFTOD işlem tipi için 1.adımda minimum hatayı veren ilk 3 model	50
Çizelge 5.8 EFTOD işlem tipi için 2.adım sonuçları	51
Çizelge 5.9 EFTOD işlem tipi için 3. adım senaryoları	51
Çizelge 5.10 EFTOD işlem tipi için en başarılı ilk üç 3. adım sonuçları	52
Çizelge 5.11 EFTOD işlem tipi için 3.adım sonunda en başarılı ilk üç sonuç	53
Çizelge 5.12 FAHES işlem tipi için 1.adımda minimum hatayı veren ilk 3 model	54
Çizelge 5.13 FAHES işlem tipi için 2.adım sonuçları	55
Çizelge 5.14 FAHES işlem tipi için 3. adım senaryoları	55
Çizelge 5.15 FAHES işlem tipi için en başarılı ilk üç 3. adım sonuçları	56
Çizelge 5.16 FAHES işlem tipi için 3.adım sonunda en başarılı ilk üç sonuç	57
Çizelge 5.17 FHEFT işlem tipi için 1.adımda minimum hatayı veren ilk 3 model	58
Çizelge 5.18 FHEFT işlem tipi için 2.adım sonuçları	59
Çizelge 5.19 FHEFT işlem tipi için 3. adım senaryoları	59
Çizelge 5.20 FHEFT işlem tipi için en başarılı ilk üç 3. adım sonuçları	60
Çizelge 5.21 FHEFT işlem tipi için 3.adım sonunda en başarılı ilk üç sonuç	61
Çizelge 5.22 FHVRH işlem tipi için 1.adımda minimum hatayı veren ilk 3 model	62
Çizelge 5.23 FHVRH işlem tipi için 2.adım sonuçları	63
Çizelge 5.24 FHVRH işlem tipi için 3.adım senaryoları	63
Çizelge 5.25 FHVRH işlem tipi için en başarılı ilk üç 3. adım sonuçları	64
Çizelge 5.26 FHVRH işlem tipi için 3.adım sonunda en başarılı ilk üç sonuç	64
Çizelge 5.27 GUMVR işlem tipi için 1.adımda minimum hatayı veren ilk 3 model	65
Çizelge 5.28 GUMVR işlem tipi için 2.adım sonuçları	66
Çizelge 5.29 GUMVR işlem tipi için 3. adım senaryoları	68
Çizelge 5.30 GUMVR işlem tipi için en başarılı ilk üç 3. adım sonuçları	68
Çizelge 5.31 GUMVR işlem tipi için 3.adım sonunda en başarılı ilk üç sonuç	69
Çizelge 5.32 GUMVR işlem tipi için 3.adım sonunda en başarılı ilk üç sonuç	69
Çizelge 5.33 HABRM işlem tipi için 2.adım sonuçları	70

Çizelge 5.34	HABRM işlem tipi için 3. adım senaryoları	71
Çizelge 5.35	HABRM işlem tipi için en başarılı ilk üç 3. adım sonuçları	72
Çizelge 5.36	HABRM işlem tipi için 3.adım sonunda en başarılı ilk üç sonuç	73
Çizelge 5.37	HVALE işlem tipi için 1.adımda minimum hatayı veren ilk 3 model	74
Çizelge 5.38	HVALE işlem tipi için 2.adım sonuçları	75
Çizelge 5.39	HVALE işlem tipi için 2.adım sonuçları	75
Çizelge 5.40	HVALE işlem tipi için en başarılı ilk üç 3. adım sonuçları	76
Çizelge 5.41	HVALE işlem tipi için 3.adım sonunda en başarılı ilk üç sonuç	77
Çizelge 5.42	MAASO işlem tipi için 1.adımda minimum hatayı veren ilk 3 model	78
Çizelge 5.43	MAASO işlem tipi için 2.adım sonuçları	79
Çizelge 5.44	MAASO işlem tipi için 3. adım senaryoları	79
Çizelge 5.45	MAASO işlem tipi için en başarılı ilk üç 3. adım sonuçları	80
Çizelge 5.46	MAASO işlem tipi için 3.adım sonunda en başarılı ilk üç sonuç	81
Çizelge 5.47	REZVM işlem tipi için 1.adımda minimum hatayı veren ilk 3 model	82
Çizelge 5.48	REZVM işlem tipi için 2.adım sonuçları	83
Çizelge 5.49	REZVM işlem tipi için 3. adım senaryoları	83
Çizelge 5.50	REZVM işlem tipi için en başarılı ilk üç 3. adım sonuçları	84
Çizelge 5.51	REZVM işlem tipi için 3.adım sonunda en başarılı ilk üç sonuç	85
Çizelge 5.52	SSKTA işlem tipi için 1.adımda minimum hatayı veren ilk 3 model	86
Çizelge 5.53	SSKTA işlem tipi için 2.adım sonuçları	87
Çizelge 5.54	SSKTA işlem tipi için 3. adım senaryoları	87
Çizelge 5.55	SSKTA işlem tipi için en başarılı ilk üç 3. adım sonuçları	88
Çizelge 5.56	SSKTA işlem tipi için 3.adım sonunda en başarılı ilk üç sonuç	89
Çizelge 5.57	VERGI işlem tipi için 1.adımda minimum hatayı veren ilk 3 model	90
Çizelge 5.58	VERGI işlem tipi için 3. adım senaryoları	91
Çizelge 5.59	VERGI işlem tipi için en başarılı ilk üç 3. adım sonuçları	91
Çizelge 5.60	VERGI işlem tipi için 3.adım sonunda en başarılı ilk üç sonuç	92
Çizelge 5.61	VRMAN işlem tipi için 1.adımda minimum hatayı veren ilk 3 model	93
Çizelge 5.62	VRMAN işlem tipi için 2.adım sonuçları	94
Çizelge 5.63	VRMAN işlem tipi için 3. adım senaryoları	94
Çizelge 5.64	VRMAN işlem tipi için en başarılı ilk üç 3. adım sonuçları	95
Çizelge 5.65	VRMAN işlem tipi için 3.adım sonunda en başarılı ilk üç sonuç	96
Çizelge 5.66	YDFON işlem tipi için 1.adımda minimum hatayı veren ilk 3 model	97
Çizelge 5.67	YDFON işlem tipi için 2.adım sonuçları	98
Çizelge 5.68	YDFON işlem tipi için 3. adım senaryoları	98
Çizelge 5.69	YDFON işlem tipi için en başarılı ilk üç 3. adım sonuçları	99
Çizelge 5.70	YDFON işlem tipi için 3.adım sonunda en başarılı ilk üç sonuç	100
Çizelge 5.71	Her bir işlem tipi için en iyi tahmini veren senaryo-makine öğrenmesi algoritması ikilileri	104
Çizelge 5.72	Her bir işlem tipi için makine öğrenmesi algoritmalarının modelleme başarısı	107
Çizelge 5.73	Her bir işlem tipi için çalışma sonucunda elde edilen en iyi model bilgileri	111

OPERASYON İŞLEMLERİNİN HIZLANDIRILMASINDA VERİ MADENCİLİĞİNİN KULLANILMASI

Seyhan AMASYALI

Bilgisayar Mühendisliği Anabilim Dalı
Yüksek Lisans Tezi

Tez Danışmanı: Yrd. Doç. Dr. Banu DİRİ

Bilinmeyen geleceğin bilimsel yöntemlerle kestirilmesi ve gelecek için önceden hazırlıkların yapılması her alanda olduğu gibi özellikle ekonomide ve finans sektöründe büyük önem taşımaktadır. Bu tez çalışmasında; gerçek veriler kullanılarak bir bankanın operasyon merkezinde gerçekleşen iş süreçleri analiz edilmiş ve geleceğe yönelik tahmin modelleri oluşturulmuştur. Özellikle yoğun zamanlarda kaynakların etkin kullanımına imkan sağlayan bu çalışmayla operasyonel işlemlerin hızlandırılması mümkün hale gelmiştir.

Bu çalışmada her bir operasyonel iş süreci için; klasik zaman serisi algoritmaları (Ekonometrik Modeller, Elman Ağ Model, Markov Rejim Değişim Modeli) ile makine öğrenmesi algoritmaları (M5 Kuralları, Karar Tablosu, Birleşik Kural, REP Ağacı, Gauss Süreçleri, Eş Aralıklı Regresyon, Doğrusal Regresyon, Yapay Sinir Ağı, Basit Doğrusal Regresyon, Karar Destek Vektörleriyle Regresyon, Ibk, KStar, Toplamsal Regresyon, Torbalama) denenmiş ve sonuçlar karşılaştırılarak en iyi tahmini gerçekleştiren model oluşturulmuştur.

Çalışma sonucunda makine öğrenmesi algoritmalarının klasik zaman serisi algoritmalarına göre daha başarılı sonuçlar verdiği görülmüştür. Özellikle karar ağacı tabanlı makine öğrenmesi algoritmalarının performansları diğerlerine oranla daha yüksek çıkmıştır. Ayrıca her bir iş sürecinin kendine özgü özelliklere sahip olmasından dolayı ayrı ayrı modellenmesi gerektiği sonucuna ulaşılmıştır.

Anahtar Kelimeler: Zaman Serileri Analizi, Makine Öğrenmesi Algoritmaları, ARIMA Modeli, Elman Ağ Model, Markov Rejim Değişim Modeli

**ACCELERATING OPERATIONAL PROCESSES BY USING DATA MINING
TECHNIQUES**

Seyhan AMASYALI

Department of Computer Engineering

MSc. Thesis

Advisor: Assist. Prof. Dr. Banu DİRİ

Forecasting unknown future by scientific methods and making preparations for future in advance are of great importance in every field, especially in the economy and the financial sector. In this thesis; by using real data, a bank's operation processes have been analyzed and future oriented forecast models have been established. By this study; especially at intense times, effective use of resources have been achieved, so operational transactions can be accelerated.

For each operational processes, classical time series algorithms (Econometric Models, Elman Network Model, Markov Regime Change Model) and machine learning algorithms (M5 Rules, Decision Table, Conjunctive Rule, REP Tree, Gaussian Processes, Isotonic Regression, Linear Regression, Multilayer Perceptron, Simple Linear Regression, SMOreg, IBK, Kstar, Additive Regression, Bagging) have been run. Results have been compared and model which performs the best estimate has been established.

The experimental results in this study have showed that machine learning algorithms have superior performance than classical time series algorithms. Especially the performances of decision-tree-based machine learning algorithms have been higher than others. In addition, it is found that each operational processes should be modeled separately because of each peculiar features.

Key words: Time Series Analysis, Machine Learning Algorithms, ARIMA Model, Elman Network Model, Markov Regime Change Model

1.1 Literatür Özeti

Zaman serilerinin modellenmesinde literatürde birçok çalışma yapılmıştır. Bu bölümde bunların bir kısmına yer verilmiştir.

Kaynar ve Tastan [1] tarafından yapılan çalışmada Box-Jenkins modelleri [2] ile ileri beslemeli Yapay Sinir Ağlarının (YSA) bir karşılaştırması yapılmıştır. Veri seti olarak aylık ve günlük döviz (YTL/\$) kuru verileri kullanılmıştır. Farklı ARIMA ve geri yayımlı Çok Katmanlı Algılayıcı (MLP) tipi YSA modelleri oluşturulmuş, her bir teknik için en iyi sonuçları veren modeller seçilerek karşılaştırma yapılmıştır. Elde edilen sonuçlar; YSA'nın, finansal verilerin tahmininde kullanılabilecek başarılı bir yöntem olduğunu göstermiştir.

Hamzaçebi ve Kutay [3] tarafından yapılan çalışmada uzun dönemli elektrik enerjisi tüketimi tahmininde yapay sinir ağlarının kullanılması araştırılmıştır. YSA olarak MLP ve Radyal Tabanlı Fonksiyon (RBF) tipi modeller kullanılmıştır. YSA teknikleri ile bulunan sonuçlar, ARIMA modelleri ve regresyon tekniği ile karşılaştırılmıştır. Bulunan sonuçlar YSA'nın elektrik enerjisi tüketiminde iyi bir tahmin aracı olduğunu göstermiştir.

Çuhadar vd. [4] tarafından yapılan çalışmada, zaman serisi yöntemlerinden Üstel Düzleştirme ve Box-Jenkins yöntemleri ile farklı mimarilere sahip YSA modellerinin tahmin doğrulukları karşılaştırılarak en yüksek doğruluğu sağlayan modelin belirlenmesi ve belirlenen model yardımıyla Antalya iline yönelik aylık dış turizm talebi tahminlerinin yapılması amaçlanmıştır. Yapılan çok sayıda deneme sonucunda orijinal seri değerleri kullanılarak oluşturulan 12 gecikmeli YSA modelinin en yüksek doğruluğu

sağladığı görülmüş ve elde edilen model yardımıyla 2009 yılı için Antalya iline yönelik aylık dış turizm talebi tahminleri yapılmıştır.

Kaynar vd. [5] tarafından yapılan çalışmada, ham petrol fiyatlarını tahmin etmek için klasik zaman serileri analiz yöntemlerinden ARIMA ile veri seti içerisindeki karmaşık ilişkileri başarıyla modelleyebilen MLP ve RBF yapay sinir ağları kullanılmıştır. Gerek MLP, gerekse RBF yapay sinir ağları kullanılarak elde edilen tahmin sonuçları; ARIMA ile elde edilen tahmin değerlerinden daha iyi performans sergilemişlerdir. Sonuç olarak; uygun ağ yapısı ve yeterli sayıda veri kullanıldığında, zaman serilerinin tahmininde yapay sinir ağlarının istatistiksel yöntemlere alternatif bir yöntem olarak kullanılabileceği ifade edilmiştir.

Gobenez [6] yıllık büyüme oranını, bir Otoregresif Model (AR) ve bir YSA simülatörü kullanarak modellemiştir. Sonuçlar göstermiştir ki YSA model yardımıyla elde edilen tahmin hatası AR modeli ile elde edilenden daha küçüktür.

Akgül vd. [7] tarafından yapılan çalışmada, Türkiye'nin cari işlemler dengesinin Markov Rejim Değişim Modelleri ile modellenip modellenemeyeceği araştırılmış ve sonuçta anılan serinin Markov Rejim Değişim Modelleri ile başarılı bir şekilde tanımlandığı saptanmıştır.

Bildirici ve Bozoklu [8] tarafından yapılan çalışmada; yatırımcıların geleceğe yönelik bekleyişlerindeki iyimserlik veya kötümserlik dalgalanmasının, ekonomiyi etkileyip etkilemeyeceği MS-VAR (Markov Rejim Değişim – Vektör OtoRegresif) modeli kullanılarak test edilmiştir. Elde edilen sonuçlar hayvansal güdüler hipotezinin Türkiye için geçerli olduğunu ortaya koymaktadır.

Mohammadi vd. [9] tarafından yapılan çalışmada, kanalizasyonlara giren kar sularının miktarlarının tahmini yapılmıştır. Bu amaçla YSA, ARIMA ve Doğrusal Regresyon olmak üzere üç metot karşılaştırılmıştır. Sonuçlara göre YSA, diğer iki metoda göre daha başarılı tahminlere sahiptir.

Lahane [10] tarafından borsanın gelecekteki değerlerinin tahmini üzerine yapılan çalışmada ARIMA, Karar Destek Makineleri ve YSA'ların performansları karşılaştırılmıştır. Ayrıca bu konuda daha önce yapılmış çalışmaların bir özeti verilmiştir. Bu özetle; YSA'ların ARIMA'dan daha iyi sonuçlar ürettiği Azo [11], Kumar ve

Thenmozhi [12], Neeraj [13] çalışmalarına, Karar Destek Makinelerinin ARIMA'dan daha iyi sonuçlar ürettiği Chen vd. [14] çalışmasına, YSA'ların Karar Destek Makinelerinden daha iyi sonuçlar ürettiği Trafalis ve Ince [15] çalışmasına, Karar Destek Makinelerinin YSA'lardan daha iyi sonuçlar ürettiği Cao ve Tay [16] çalışmalarına değinilmiştir. Yapılan çalışmada ise bu metotlar Hindistan'daki üç borsanın değerlerini tahmin etmede kullanılmıştır. Sonuçlara göre bir gün sonraki borsa değerini tahmin etmede YSA'nın, bir gün sonraki borsanın yönünü tahmin etmede ise ARIMA'nın daha başarılı olduğu görülmüştür.

Wijaya vd. [17] tarafından yapılan çalışmada, Endonezya borsasının bileşik endeksinin tahmininde YSA ve ARIMA modelleri karşılaştırılmış ve YSA'ların tahmin başarısının daha yüksek olduğu görülmüştür.

Xie vd. [18] (2006) tarafından yapılan çalışmada, petrol fiyatlarının tahmini için Destek Vektör Makinesi (SVM), YSA ve ARIMA modelleri karşılaştırılmıştır. Sonuçlara göre SVM diğer iki modelden de daha başarılı sonuçlar üretmiştir.

Zaman serileri tahmini için yapılan çalışmalar genel olarak incelendiğinde aşağıdaki sonuçlara varılmıştır:

- Çeşitli modeller (ARIMA, YSA, Markov Rejim Değişim Modelleri vb...) arasında birçok karşılaştırma yapılmıştır. Bazı çalışmalar bir modelin, bazı çalışmalar ise bir başka modelin daha iyi olduğunu göstermiştir.
- Özellikle ARIMA ve YSA'lar arasında karşılaştırmalar yapılmıştır.
- En iyi modelin hangisi olduğu hakkında genel bir sonuca varmak mümkün değildir.
- İncelenen verinin türü en iyi modelin seçimini etkilemektedir.

Bu nedenle önceki çalışmalara paralel olarak; bu tezde her bir operasyonel süreç için hem klasik zaman serisi metotları, hem de makine öğrenmesi metotları kullanılmış ve sonuçlar karşılaştırılarak en iyi model seçilmiştir.


1.2 Tezin Amacı

Zaman serileri analizi, belirli zaman aralıklarında gözlenen bir olay hakkında geleceğe yönelik tahmin kurmada kullanılan bir yöntemdir. Bu konuda birçok alanda farklı çalışmalar yapılmıştır. Teorik olarak istatistik ve ekonometri bilimlerinde yapılan çalışmalar fazla olmakla birlikte uygulama alanı çok geniştir. Tıp, mühendislik, işletme ve ekonomi gibi daha birçok alanda bu konuda yapılmış çalışmalar bulunmaktadır.

Bu tez çalışması; bir bankanın operasyon merkezinde gerçekleşen iş süreçlerini analiz ederek, bu süreçlerin gelecekte nasıl gerçekleşeceğini modellemeyi içermektedir. Modelleme işlemi için bankadan alınan gerçek veriler kullanılmıştır.

Bankadaki mevcut sistemde, müşteri istekleri çeşitli kanallardan (şube, internet, telefon...) operasyon merkezine ulaştırılır. İstekler operasyon merkezine gönderilirken, isteğin içeriğini ifade edecek şekilde işlem tanımları oluşturulur. Örneğin; müşteri havale yapmak istemişse, buna uygun (HVALE kodlu) işlem tipinde bir istek operasyon merkezine gönderilir. Mevcut sistemde 200 tane işlem tipi (operasyonel süreç) vardır. Her bir işlem tipinin de ne kadar süre içerisinde bitirilmesi gerektiği (hedef süreye uyumluluk) ve gün içinde en geç bitirilme zamanı belirlenmiştir. Bir işlem operasyon merkezine ulaştığında ise; tip, öncelik, hedef süreye uyumluluk gibi parametrelere göre operasyon merkezinin iş kuyruklarından birine atanır ve kuyruğu işlemekle sorumlu operasyon görevlileri tarafından işlem gerçekleştirilir.

Operasyon merkezindeki iş kuyrukları, merkezdeki iş birimlerine göre tanımlanmıştır. Buna göre, operasyon merkezi temel olarak dört birimden (Hesap İşlemleri, Dış Ticaret ve Krediler, Bilgi Yönetimi ve İç Kontrol) oluşmaktadır. Bu tez çalışmasında Hesap İşlemleri biriminin sorumluluğundaki 13 adet süreç ile ilgili analiz yapılmıştır. Operasyon merkezinin genel çalışması Şekil 1.1’de gösterilmektedir.



Şekil 1.1 Operasyon merkezinin genel çalışma şekli

Ay sonu, vergi ödeme günü gibi özel günlerde veya sistemsel problemlerde yaşanan normalin üstündeki yoğunluklar; sistemin işleyişinde gecikmelere sebep olmaktadır. Oluşacak yoğunluğun hacmi mevcut sistem tarafından bilinemediği için, önceden herhangi bir aksiyon alınması mümkün olmamaktadır. Bu nedenle, bazen işlemlerin hedeflenen sürede bitirilmesi ile ilgili sıkıntılar yaşanması söz konusu olmaktadır. Bunu önleyebilmek için; yönetmenler standart işlerinin yanı sıra, kuyruklardaki iş sayısını kontrol edip yoğunluk olduğu durumlarda iş yükünü elle düzenlemekle görevlidir. Bu düzenlemeyi; ya işleri yoğun olan kuyruklardan daha az yoğun olan kuyruklara transfer ederek ya da daha az yoğun kuyrukta çalışan kişilerin yoğun kuyruklarda çalışmasını sağlayarak gerçekleştirmektedirler. Ancak bu yönlendirme kararı, tamamen sezgisel bilgiye dayanmaktadır ve kişiye özeldir. Ayrıca anlık bir aksiyondur, yoğunluk öncesi alınan bir tedbir değildir. Daha yoğunluk yaşanmadan alınabilecek aksiyon ise, yine tamamen yönetmenin insiyatifinde olmak üzere, kişilerin hangi kuyruklarda çalışacağını belirlenmesidir. Fakat tüm bunlar sezgisel bilgiye dayanmaktadır.

1.3 Hipotez

Bu çalışmada her bir işlem tipi için; klasik zaman serisi algoritmaları (Ekonometrik Modeller, Elman Ağ Model, Markov Rejim Değişim Modeli) ile makine öğrenmesi algoritmaları (M5 Kuralları, Karar Tablosu, Birleşik Kural, REP Ağacı, Gauss Süreçleri, Eş Aralıklı Regresyon, Doğrusal Regresyon, Yapay Sinir Ağı, Basit Doğrusal Regresyon, Karar Destek Vektörleriyle Regresyon, İbk, Kstar, Toplamsal Regresyon, Torbalama) denenmiş ve sonuçlar karşılaştırılarak en iyi tahmini gerçekleştiren sistem oluşturulmuştur. Yapılan bu çalışma ile yönetmenlerin gelecek bir ay için işlem

sayılarını tahmin eden bir sisteme sahip olmaları mümkün olmuştur. Bu sayede yoğunluğu önceden fark edecek olan yönetmenler gerekli düzenlemeleri yoğunluk öncesinde yapabilecekler ve yaşanan yoğunluğun azaltılması mümkün olabilecektir. Böylece, kaynaklar daha etkin kullanılabilir.

BÖLÜM 2

ZAMAN SERİLERİ

İlgilenilen zamana bağlı bir olayın, gözlem veya deney sonucu aldığı değerlerin oluşturduğu topluluğa zaman serisi denir (Chatfield [19]). Zaman serisine örnek olarak, İstanbul Menkul Kıymetler Borsası endeksinin günlük kapanış değeri veya Türkiye'deki Kızılırmak nehrinin yıllık akış hacmi verilebilir.

Bir zaman serisinin durağan olması, zaman içinde varyansın, ortalamasının ve otokovaryansın sabit olması demektir. Eğer bir stokastik süreç durağan değilse, serinin davranışı sadece ele alınan tahmin dönemi için geçerli olacaktır; ancak seri hakkında diğer dönemler için başarılı bir genelleme yapılamayacaktır. Zaman serisinin durağan olmaması durumunda farkı alınarak durağanlaştırılmaktadır (Sevüktekin vd. [20]).

Zaman serileri analizi ise, belirli zaman aralıklarında gözlenen bir olay hakkında, gözlenen serinin yapısını veren stokastik süreci modellemeyi ve geçmiş dönemlere ilişkin gözlem değerleri yardımıyla geleceğe yönelik tahminler yapmayı içermektedir. İşletme, ekonomi ve finans alanında yaygın olarak kullanılan zaman serileri analizi ile yapılan tahminler, gerek ülke ekonomisi gerekse işletme temelinde yapılacak geleceğe yönelik planlama çalışmaları açısından son derece önemlidir.

Geleneksel istatistiksel zaman serileri yöntemleri, performansı iyi olmasına rağmen yapısında pek çok sınırlamalara sahiptir. Örneğin, Box-Jenkins (Otoregresif Hareketli Ortalama Modeli, ARIMA) yaklaşımı doğrusal yapıya sahip olup, doğrusal olmayan davranışları modellemede zorlanabilir. Bu nedenle zaman serilerinin analizinde; ekonometrik modellerin yerine makine öğrenmesi algoritmalarının kullanılması son zamanlarda yaygınlaşmaya başlamıştır. Bu çalışmada da makine öğrenmesi

algoritmaları zaman serisi tahminlerinde kullanılmış ve elde edilen sonuçlar geleneksel zaman serisi metotlarıyla elde edilenlerle karşılaştırılmıştır.

2.1 Zaman Serilerinin Bileşenleri

Zaman serilerinin gözlem değerlerinde, zaman içinde azalma ya da artma şeklinde, bazı değişimler gözlenir. Ekonomik, sosyal, psikolojik vb. çeşitli nedenlerin zaman serisi gözlem değerleri üzerindeki, yön ve şiddetinin farklı olmasından ileri gelen bu değişimler; trend, mevsimsel değişimler, konjonktürel değişimler ve rassal değişimler olarak sayılabilir. Bu değişimlere, genel olarak, zaman serisi bileşenleri ya da temel faktörleri adı verilir. Bu bileşenlerin özellikleri aşağıda ele alınmaktadır.

2.1.1 Trend Bileşeni

Bir zaman serisinin uzun zaman döneminde (en az 7 yıl) belli bir yöne doğru gösterdiği genel eğilime uzun devre eğilimi (trend) veya ana eğilim adı verilir (Serper [21]). Trend bileşeni, zamana bağlı değişken üzerindeki genel eğilime neden olan uzun dönemli etkileri açıklar. Bu etkileri genel olarak; demografik özelliklerdeki, coğrafi dağılımdaki, kişi başına gelirdeki, teknolojik gelişmelerdeki, tüketici alışkanlıklarındaki değişimlerdeki vb. etkiler olarak sıralamak mümkündür.

Yukarıda belirtilen etkilerin şiddetine bağlı olarak, artış ve azalış yönündeki değişimler, bazen artabilir ya da yavaşlayabilir, yani trend aynı kalmaz. Trend doğrusal ya da eğrisel olabilir (Yılmaz [22]). Diğer taraftan zaman içinde artış ya da azalış göstermeyen, hemen hemen aynı düzeyde kararlılık gösteren serilerin trendi yoktur.


2.1.2 Mevsimsel Bileşen

Bir zaman serisinin, birbirini izleyen yılların aynı aylarında göstermiş olduğu aynı veya benzer dalgalanmalar, mevsimsel dalgalanmalar olarak ifade edilir (Atlas [23]).

Örneğin; ülkemiz deniz turizmi için önemli bir ülke olduğundan, yaz mevsimlerinde ülkemize gelen yabancı turist sayısı artar, kış mevsimlerinde azalır; işe gidiş ve işten dönüş saatlerinde şehir içi toplu taşıma araçlarında yolcu sayıları artar, diğer saatlerde

azalır; cumartesi ve pazar günleri tatil olduğu için büyük alışveriş merkezlerinin satışları artar, hafta içi günlerde azalır.

Mevsimsel değişme gösteren bir zaman serisinin kartezyen grafiği Şekil 2.1’de verilmiştir. Çeyrek yıllık gözlem değerlerinden oluşan bu serinin kartezyen grafiği incelendiğinde, serinin rassal dalgalanmaların yanında trend ve birbirini izleyen yılların IV. çeyreklerinde maksimum, II. çeyreklerinde minimum değerler alma eğilimine sahip olan mevsimsel bileşenin etkisi altında olduğu söylenebilir.



Şekil 2.1 Örnek bir zaman serisinin kartezyen grafiği

Birbirini izleyen iki mevsimsel değişimin maksimum noktaları arasındaki zaman aralığına dalga uzunluğu adı verilir. Genellikle mevsimsel değişmelerin dalga uzunlukları birbirine eşittir. Şekil 2.1 incelendiğinde mevsimsel değişmelerin dalga uzunluklarının 4 çeyrek yıl olduğu görülmektedir. Mevsimsel değişmeler, dalga uzunluklarının birbirine eşit olması nedeniyle periyodik, tekrar tekrar meydana gelmiş olmaları nedeniyle de döngüsel özelliğe sahip değişmelerdir (Atlas [23]).

Bir mevsimsel değişimin maksimum ve minimum noktası arasındaki yükseklik farkına dalga şiddeti adı verilir. Mevsimsel değişmelerin dalga şiddetleri, Şekil 2.1’de görüldüğü gibi, farklı ya da eşit olabilir.

2.1.3 Konjonktürel Bileşen

Ekonomi ve iş idaresi alanlarıyla ilgili değişkenlerde genellikle, sabit bir oranda artış ya da azalış görülmez. Trend düzeyi etrafında, iki ile on yıl ya da daha fazla yıl zaman aralıklarıyla, herhangi bir dönemde, artma ya da azalma şeklinde tekrarlanabilen

değişmeler gözlenir. Konjonktürel değişme adı verilen bu değişmelerin etkisini açıklayan bileşene “konjonktürel bileşen” denir. Konjonktürel bileşenin açıkladığı değişmeler periyodik olmayan, ancak döngüsel olan değişmelerdir (Serper [21]). Örnek olarak; bir ekonomik kriz durumundan bütün ekonomik göstergelerin etkilenip düşüşe geçmesi, sonrasında uygulanan tedbirlerle ve zamanla tekrar yükselişe geçmesi durumu verilebilir. Konjonktürel değişmelerin sadece ekonomik faktörlerdeki değişmelerden meydana gelmesi gerekmez. Örneğin; modadaki değişmeler, belirli bir ürünün satışları üzerinde döngüsel değişmelere neden olabilir.

2.1.4 Rassal Bileşen

Diğer unsurlar gibi belirli olmayan, hata terimi ile ifade edilebilecek düzensiz değişmelere rassal değişme adı verilir. Zaman serileri üzerinde trendin, mevsimsel bileşenin ve konjonktürel bileşenin etkisi ayrıştırıldıktan sonra geride kalan etkiyi açıklayan bileşendir. Düzensiz hareketler düzenlilik göstermedikleri ve rassal oldukları için, bunların ne zaman ve ne şiddetle ortaya çıktıkları (kabaca bile olsa) önceden tahmin edilemezler (Serper [21]). Örneğin; deprem, siyasal karışıklıklar, rakip firmaların politikalarındaki değişiklikler vb. gibi etkiler, rassal değişmelere neden olur.

VERİ TOPLAMA VE ÖN İŞLEME

Bu bölümde veri toplama adımı ve veride gerçekleştirilen ön işlemler anlatılmıştır.


3.1 Veri Toplama

Bu çalışmada verisi kullanılan bankanın Hesap İşlemleri biriminin sorumluluğundaki aşağıdaki 13 adet operasyonel süreç ile ilgili analiz yapılmış ve süreçlere karşılık gelen işlem tiplerinin gelecekteki adetleri tahmin edilmiştir (Süreçlere ait detaylı açıklamalar, bankaya ait gizli bilgi olması sebebiyle verilmemiştir).


- EFTOD : EFT işlemi
- FAHES : Toplu hesap işlemi
- FHEFT : Toplu EFT işlemi
- FHVRH : Virman işlemi
- GUMVR : Gümrük vergisi tahsilatı
- HABRM : Yanlış işlem tipi bildirimi
- HVALE : Havale işlemi
- MAASO : Maaş ödemesi
- REZVM : Rezerv mevduatı
- SSKTA : Sosyal Sigortalar Kurumu (SSK) tahsilatı
- VERGI : Vergi tahsilatı
- VRMAN : Virman

- YDFON : Yurt dışı çıkış fonu


Analiz için 1 Ocak 2009 – 23 Temmuz 2010 aralığındaki yaklaşık 1.5 yıllık gerçek veri kullanılmıştır. Veriler; SQL Server veri tabanında her istek tabloda bir satıra karşılık gelecek ve isteğin geliş zamanı, şubesi vb. bilgilerini içerecek şekilde çeşitli tablolarda tutulmaktadır. Bu nedenle; tablolardaki her satır, işlem tipine ve zaman bilgisine göre gruplandırılmış; 1 Ocak 2009 – 23 Temmuz 2010 aralığında her işlem tipi için günlük kaç adet istek geldiği bilgisi elde edilmiştir. Şekil 3.1-3.13’de her bir işlem tipine ait günlük adetler gösterilmektedir (Şekiller daha anlaşılabilir olması için sadece 2010 yılını içermektedir).




Şekil 3.1 EFTOD işlem tipine (eft işlemine) ait günlük adetler




Şekil 3.2 FAHES işlem tipine (toplu hesap işlemine) ait günlük adetler




Şekil 3.3 FHEFT işlem tipine (toplu eft işlemine) ait günlük adetler




Şekil 3.4 FHVRH işlem tipine (virman işlemine) ait günlük adetler




Şekil 3.5 GUMVR işlem tipine (gümrük vergisi tahsilat işlemine) ait günlük adetler




Şekil 3.6 HABRM işlem tipine (yanlış işlem tipi bildirim işlemine) ait günlük adetler




Şekil 3.7 HVALE işlem tipine (havale işlemine) ait günlük adetler




Şekil 3.8 MAASO işlem tipine (maaş ödemesi işlemine) ait günlük adetler




Şekil 3.9 REZVM işlem tipine (rezerv mevduat işlemine) ait günlük adetler




Şekil 3.10 SSKTA işlem tipine (SSK tahsilat işlemine) ait günlük adetler



Şekil 3.11 VERGI işlem tipine (vergi tahsilat işlemine) ait günlük adetler



Şekil 3.12 VRMAN işlem tipine (virman işlemine) ait günlük adetler




Şekil 3.13 YDFON işlem tipine (yurt dışı çıkış fonu işlemine) ait günlük adetler

3.2 Veri Ön İşlemleri


Verilerin daha etkin işlenebilmesi için veri üzerinde 4 farklı ön işlem gerçekleştirilmiştir.

- Hafta sonlarının silinmesi : Tahminde kullanılmadığı ve veri kirliliğine sebep olmaması için hafta sonları silinmiştir.
- Resmi tatil günlerinin normalizasyonu : Resmi tatil günlerinde işlem yapılmadığından bu günlere ilişkin 0 değerlerinin, şablonların ortaya çıkarılmasında sorun oluşturduğu gözlenmiştir. Bu nedenle; resmi tatil günleri için kendisinden önceki 5 iş gününün ortalaması normalizasyon değeri olarak kullanılmıştır.
- Aykırı noktaların normalizasyonu : Ortalamaya standart sapmanın 3 katından daha uzak olan noktalar aykırı nokta olarak değerlendirilmiş ve aykırı noktanın mevcut değeri yerine, (minimum - maximum oluşuna göre) aykırı nokta olmayan en yakınındaki noktanın değeri atanmıştır. Şekil 3.14-3.26'da her bir işlem tipi için gerçekleştirilen resmi tatil ve aykırı nokta normalizasyonları gösterilmiştir.


Grafikteki küçük kareli noktalar, normalizasyon yapılan noktaları ifade etmektedir.




Şekil 3.14 EFTOD - resmi tatil ve aykırı nokta normalizasyonu




Şekil 3.15 FAHES - resmi tatil ve aykırı nokta normalizasyonu




Şekil 3.16 FHEFT - resmi tatil ve aykırı nokta normalizasyonu




Şekil 3.17 FHVRH - resmi tatil ve aykırı nokta normalizasyonu




Şekil 3.18 GUMVR - resmi tatil ve aykırı nokta normalizasyonu




Şekil 3.19 HABRM - resmi tatil ve aykırı nokta normalizasyonu




Şekil 3.20 HVALE - resmi tatil ve
aykırı nokta normalizasyonu




Şekil 3.21 MAASO - resmi tatil ve
aykırı nokta normalizasyonu




Şekil 3.22 REZVM - resmi tatil ve
aykırı nokta normalizasyonu




Şekil 3.2 SSKTA - resmi tatil ve
aykırı nokta normalizasyonu



Şekil 3.3 VERGI - resmi tatil ve
aykırı nokta normalizasyonu



Şekil 3.4 VRMAN - resmi tatil ve
aykırı nokta normalizasyonu




Şekil 3.5 YDFON - resmi tatil ve aykırı nokta normalizasyonu


- Aralık normalizasyonu : Tüm değerler 0-1 arasına çekilmiştir.

3.3 İşlem Tipleri İçin Geçmiş Gün Korelasyonlarının Analizi

Her bir işlem tipi için, 60 günlük geçmiş gün korelasyonu incelenmiş ve verinin gösterim şekillerinin oluşturulmasında bu korelasyon bilgileri de göz önünde bulundurulmuştur.




Şekil 3.27 EFTOD – 60 günlük geçmiş gün korelasyonu




Şekil 3.28 FAHES – 60 günlük geçmiş gün korelasyonu

EFTOD işlem tipinin korelasyon grafiğine bakıldığında, 10 günde bir tekrarlanan baskın bir şablon olduğu dikkat çekmektedir. Ayrıca kendisinden önceki 3 geçmiş gün ile de ilişkisi gözükmektedir.

FAHES işlem tipinin korelasyon grafiğine bakıldığında, yaklaşık 20 günde (ayda) bir tekrarlanan baskın bir şablon olduğu dikkat çekmektedir.




Şekil 3.29 FHEFT – 60 günlük
geçmiş gün korelasyonu




Şekil 3.30 FHVRH – 60 günlük
geçmiş gün korelasyonu

FHEFT işlem tipinin korelasyon grafiğine bakıldığında, 5 günde bir tekrarlanan baskın bir şablon olduğu görülmektedir.

FHVRH işlem tipinin korelasyon grafiğine bakıldığında; FAHES işlem tipine çok benzer olarak, 5 günde bir tekrarlanan baskın bir şablon olduğu dikkat çekmektedir.




Şekil 3.31 GUMVR – 60 günlük
geçmiş gün korelasyonu




Şekil 3.32 HABRM – 60 günlük
geçmiş gün korelasyonu

GUMVR işlem tipinin korelasyon grafiğine bakıldığında; diğer işlem tiplerinden farklı olarak, bu işlem tipinin tüm geçmiş günlerle çok ilişkili bir yapıya sahip olduğu görülmektedir (yüksek korelasyon değerlerine sahiptir). Grafikte, 5 günde bir tekrarlanan bir şablon daha baskındır. Ayrıca; tüm geçmiş 60 gün için gittikçe azalan değerde korelasyona sahiptir.

HABRM işlem tipinin korelasyon grafiğine bakıldığında, 5 ve 10 günde bir tekrarlanan bir şablon olduğu dikkat çekmektedir. Özellikle 10 günde bir tekrarlanan şablon daha baskındır. Ayrıca; bir önceki geçmiş gün ile de yüksek korelasyona sahiptir.




Şekil 3.33 HVALE – 60 günlük
geçmiş gün korelasyonu




Şekil 3.34 MAASO – 60 günlük
geçmiş gün korelasyonu

HVALE işlem tipinin korelasyon grafiğine bakıldığında, 5 günde bir tekrarlanan baskın bir şablon olduğu dikkat çekmektedir.

MAASO işlem tipinin korelasyon grafiğine bakıldığında, ayda bir tekrarlanan baskın bir şablon fark edilmektedir. Ayrıca; bir önceki geçmiş gün ile de yüksek korelasyona sahiptir.




Şekil 3.35 REZVM – 60 günlük
geçmiş gün korelasyonu




Şekil 3.36 SSKTA – 60 günlük
geçmiş gün korelasyonu

REZVM işlem tipinin korelasyon grafiğine bakıldığında; diğer işlem tiplerinden farklı olarak, bu işlem tipinin geçmiş günlerle çok ilişkili bir yapıya sahip olduğu görülmektedir. Tüm geçmiş 60 gün için yüksek değerlerde korelasyona sahiptir.

SSKTA işlem tipinin korelasyon grafiğine bakıldığında, ayda bir tekrarlanan baskın bir şablon olduğu dikkat çekmektedir.




Şekil 3.37 VERGI – 60 günlük
geçmiş gün korelasyonu



Şekil 3.38 VRMAN – 60 günlük
geçmiş gün korelasyonu

VERGI işlem tipinin korelasyon grafiğine bakıldığında, ayda bir tekrarlanan baskın bir şablon olduğu dikkat çekmektedir. Ayrıca; 10 günde bir tekrarlanan daha az baskın bir şablon da gözükmemektedir.

VRMAN işlem tipinin korelasyon grafiğine bakıldığında, 5 günde bir tekrarlanan baskın bir şablon görülmektedir. Ayrıca kendisinden önceki 3 geçmiş gün ile de ilişkisi gözükmemektedir.




Şekil 3.39 YDFON – 60 günlük geçmiş gün korelasyonu

YDFON işlem tipinin korelasyon grafiğine bakıldığında, kendisinden önceki 5 geçmiş gün ile ilişkisinin yüksek olduğu görülmektedir.

BÖLÜM 4

KULLANILAN ALGORİTMALAR

Bu çalışmada kullanılan algoritmalar temel olarak iki kategoride değerlendirilebilir : klasik zaman serisi algoritmaları ve makine öğrenmesi algoritmaları. Zaman serisi algoritmaları, örneklerinin arasında sıra ilişkisinin olduğu veri kümelerine uygulanan algoritmalar. Kısacası zaman serisi algoritmalarının temelinde yaptığı işlem, t anındaki değeri “ $t-1 - t-k$ ” aralığındaki değerleri kullanarak bulmaktır. Diğer taraftan makine öğrenmesi algoritmalarının uygulandığı veri kümelerinin örnekleri arasında ise zamansal bir ilişki yoktur, yani verinin sırasının bir önemi yoktur. Makine öğrenmesi algoritmalarının zaman serilerine uygulanabilmesi için bu çalışmada, geçmiş zamana ait değerler örneklere ait özellikler olarak tanımlanmıştır. Örneğin 3 gün öncesi kullanılarak bir tahmin modeli oluşturulacaksa, giriş verisi Şekil 4.1’deki yapıya dönüştürülmelidir (Buradaki X_t t anındaki değeri ifade etmektedir).



Şekil 4.1 Zaman serisinin bir makine öğrenmesi algoritmasına giriş örneği

Algoritmaların performansını değerlendirirken, verinin %90’i eğitim için, %10’u test için kullanılmıştır. Performans metriği olarak ise Ortalama Karesel Hatanın Kare Kökü (Root Mean Square Error, KHK) (4.1) kullanılmıştır. Çünkü verinin içeriği gereği hatanın oranı değil miktarı daha anlamlıdır. Örneğin gerçek değer 200 iken tahmin değerinin 100

olduğu bir durum ile gerçek değer 2000 iken tahmin değerinin 1000 olduğu diğer bir durumu ele alalım. Bu iki durum için de hatanın oranı aynı olmasına rağmen, ikinci durum için hatanın sisteme etkisi daha büyüktür. Bu nedenle algoritmaların performanslarını karşılaştırırken hatanın oranını değil de farkını kullanan ortalama karesel hatanın kare kökü metriği kullanılmıştır.

$$KHKK = \sqrt{\frac{1}{N} \sum_{i=1}^N (y_i - t_i)^2} \quad (4.1)$$

(4.1) eşitliğindeki N : örnek sayısını, y_i : gerçek değeri, t_i ise : tahmin değerini ifade etmektedir.

4.1 Zaman Serisi Algoritmaları

Zaman serisi algoritmaları, örneklerinin arasında sıra ilişkisinin olduğu veri kümelerine uygulanan algoritmalarlardır. Bu çalışmada zaman serisi algoritmalarından Ekonometrik Modeller, Elman Ağ ve Markov Saklı Rejim Modeli; Matlab programlama aracı kullanılarak denenmiştir.

4.1.1 Ekonometrik Modeller

Bu çalışmada ekonometrik modeller olarak, George Box ve Gwilym Jenkins'e ithafen Box-Jenkins modelleri olarak da bilinen Otoregresif Hareketli Ortalama Modelleri kullanılmıştır.

4.1.1.1 Otoregresif (AR) Model

Bir AR modelinde, bağımlı değişken geçmişteki değerinin bir fonksiyonudur. Başka bir deyişle AR modeller bir zaman serisinin herhangi bir dönemindeki gözlem değerini, aynı serinin ondan önceki belirli sayıda dönemin gözlem değerinin ve hata teriminin doğrusal bir bileşimi olarak ifade eden modellerdir. AR modeller içerdikleri geçmiş dönem gözlem değeri sayısına göre isimlendirilirler. AR modeli bir tane geçmiş dönem gözlem değeri içeriyorsa “birinci dereceden”, iki tane geçmiş dönem gözlem değeri içeriyorsa “ikinci dereceden” ve genel olarak p tane geçmiş dönem gözlem değeri

içeriyorsa p'inci dereceden AR modeli söz konusudur (Naylor vd. [24]). Bu durum (4.2) eşitliği ile ifade edilir.

$$x_t = \phi_1 * x_{(t-1)} + \phi_2 * x_{(t-2)} + \dots + \phi_p * x_{(t-p)} + \varepsilon \quad (4.2)$$

Burada; $x_t, x_{t-1}, x_{t-2}, \dots, x_{t-p}$ geçmiş gözlem değerlerini göstermektedir. $\phi_1, \phi_2, \dots, \phi_p$ ise modelin parametreleridir. Bu parametreler t dönemine (bugünkü döneme) ait gözlem değeri x_t ile geçmiş gözlem değerleri $x_{t-1}, x_{t-2}, \dots, x_{t-p}$ arasındaki ilişkiyi gösteren ilişki katsayılarıdır. Ayrıca ε hata terimi de rassal şokları tanımlamaktadır. Genel bir şekilde AR(p) şeklinde ifade edilir.

4.1.1.2 Hareketli Ortalama (MA) Modeli

MA modeller, bir zaman serisinin herhangi bir dönemindeki gözlem değerini, aynı dönemdeki hata terimi ve ondan önceki belirli sayıda dönemin hata terimine bağlı olarak açıklayan modellerdir. Başka bir deyişle, bir zaman serisinin herhangi bir dönemindeki gözlem değerinin, aynı dönemin hata terimi ve belirli sayıda geçmiş dönemin hata terimlerinin doğrusal bir bileşimi olarak ifade edildiği modeller MA modelleridir (Naylor vd [24]).

MA modelleri içerdikleri geçmiş dönem hata terimi sayısına göre birinci dereceden, ikinci dereceden ve genel olarak q'uncu dereceden MA modelleri olarak adlandırılırlar. Buna göre bir hareketli ortalama süreci (4.3) eşitliği ile ifade edilir.

$$x_t = e_t + \theta_1 e_{t-1} + \theta_2 e_{t-2} + \dots + \theta_q e_{t-q} \quad (4.3)$$

Buradaki $e_t, e_{t-1}, e_{t-2}, \dots, e_{t-q}$ hata terimlerini ifade etmektedir. $\theta_1, \theta_2, \dots, \theta_q$ ise modelin çıkış parametreleridir. Genel şekil olarak MA(q) şeklinde ifade edilir.

4.1.1.3 Otoregresif Hareketli Ortalama (AR(I)MA) Modeli

Bu model, Box-Jenkins yaklaşımı [2] olarak da adlandırılmaktadır. Bir zaman serisi çoğunlukla hem AR ve hem de MA sürecini içermektedir. Ayrıca I (integrated) ise seri tarafından içerilen trendi ifade etmektedir.

Buna göre ARIMA modeli zaman serisinin; p dereceden kendisinin gecikmesi ile ilişkisini ifade eden AR(p) sürecini içerdiğini, q ile ifade edilen ve hata terimlerinin geçmiş

değerleri ile ilişkisini ifade eden MA(q) sürecini içerdığını ifade etmektedir. Ayrıca; eğer seri durağan değil ise serinin d dereceden farkı alınarak durağan hale getirildiği belirtilmektedir. ARIMA(p,d,q) modelinin ifadesi (4.4) eşitliği ile tanımlanabilir :


$$x_t = \phi_1 * x_{(t-1)} + \phi_2 * x_{(t-2)} + \dots + \phi_p * x_{(t-p)} + \varepsilon + e_t + \theta_1 e_{t-1} + \theta_2 e_{t-2} + \dots + \theta_q e_{t-q} \quad (4.4)$$

Bu eşitlikte; $x_t, x_{t-1}, x_{t-2}, \dots, x_{t-p}$ geçmiş gözlem değerlerini göstermektedir; serinin durağan olmaması durumunda orijinal serinin d. dereceden farkı alınmıştır. $\phi_1, \phi_2, \dots, \phi_p$ otoregresif operatör için parametre değerleridir. $e_t, e_{t-1}, e_{t-2}, \dots, e_{t-q}$ hata terimlerini ifade etmektedir. $\theta_1, \theta_2, \dots, \theta_q$ ise hareketli ortalama operatörü için parametre değerleridir. Ayrıca ε hata terimi de rassal şokları tanımlamaktadır.

Fark alma derecesi $d=0$ olduğunda bu orijinal serinin durağan olması anlamına gelir ve ARIMA modeli AR, MA ya da ARMA modeli şekline dönüşür. Fark alma derecesi $d=1$ olduğunda zaman serisi doğrusal, $d=2$ olduğunda parabolik eğri göstermektedir.

4.1.2 Elman Ağ

Elman ağı kısmi geri dönüşümlü ağıdır (Elman [25]). Geri dönüşümlü ağlarda, ağıncı çıktıları yine ağına belirli bir şekilde geri gönderilerek girdi olarak kullanılmaktadır. Bu ağlarda giriş, saklı ve çıkış katmanlarına ek olarak içerik katmanı vardır. Şekil 4.2’de bir Elman Ağ yapısı görülmektedir [26].



Şekil 4.2 Elman ağ yapısı [26]


Şekil 4.2’deki çıktı elemanları, ağıncı çıktısını dış dünyaya iletirler. Çıktı ünitelerinin bilgi işleme fonksiyonu doğrusaldır. Sadece kendilerine gelen bilgileri toplarlar. Ara katman

elemanları, hem doğrusal hem de doğrusal olmayan aktivasyon fonksiyonlarına sahip olabilirler. İçerik elemanları ara katman elemanlarının önceki aktivite değerlerini hatırlamak için kullanılmaktadır; bir önceki iterasyondaki aktivasyon değerini bir sonraki iterasyona girdi olarak taşırlar. Elman ağı, çok katmanlı algılayıcı ağının öğrenme kuralına göre öğrenmektedir. Geri dönüşümlerin (içerik elemanlarının) bağlantı ağırlıkları ise sabittir.

Elman ağlarında ağın çıktısı, hem önceki durumlara hem de ağın o andaki durumuna bağlı olarak oluşturulduğundan bu özellikleri sayesinde zaman serisi problemlerinde kolaylıkla kullanılabilirler.

4.1.3 Markov Rejim Değişim Modeli


Zaman içindeki gözlemlerimizin, tek bir dağılım yerine zaman içinde değişen birçok dağılımdan geldiği varsayımına dayanan modellerdir (Zucchini ve MacDonald [27]). Şekil 4.3’de, gözlemler zaman içinde sadece biri aktif olan iki dağılımdan gelmektedirler.



Şekil 4.3 Zaman içinde sadece biri aktif olan iki dağılımdan elde edilen gözlemler (Zucchini ve MacDonald [27])

Şekil 4.3’de özellikleri (ortalama ve varyansları) birbirinden farklı olan iki dağılım vardır. T=1,3,4 ve 6 anlarında bir dağılım, T=2 ve 5 anlarında ise diğer dağılım aktiftir. Her bir an için hangi dağılımın aktif olduğu ve aktif olan dağılımdan gelen gözlemler Şekil

4.3’de verilmiştir. Modellemeye çalıştığımız verinin bu yapıda olduğu kabul edildiğinde 1) kaç dağılımın olduğunun seçilmesi 2) dağılımların ortalama ve varyans değerlerinin bulunması 3) zaman içinde hangi dağılımın aktif olacağının belirlenmesi gerekmektedir. Bu modelin gerçekleşmesinde MS_Regress yazılımı [28] kullanılmıştır. Bu yazılımda kaç dağılımın olduğunun belirlenmesi işlemi kullanıcıya bırakılmıştır. Dağılımların özellikleri ve zamanla değişimleri ise eğitim kümesi kullanılarak yazılım tarafından belirlenmektedir. Şekil 4.4’de iki dağılımın zaman içindeki aktif olma olasılıkları verilmiştir.



Şekil 4.4 Dağılımın zaman içinde aktif olma olasılıkları [28]

Şekil 4.4’e göre bir test örneğinin çıkışını belirlemek için test örneğinin zamanına bakarak o anda hangi dağılımın aktif olduğu bulunmakta, daha sonra o dağılıma ait ortalama ve varyans değerleri kullanılarak çıkışın ortalaması ve sapması hesaplanmaktadır.

4.2 Makine Öğrenmesi Algoritmaları

Zaman serilerinin analizinde; ekonometrik modellerin yerine makine öğrenmesi algoritmalarının kullanılması son zamanlarda yaygınlaşmaya başlamıştır. Bu çalışmada M5 Kuralları, Karar Tablosu, Birleşik Kural, REP Ağacı, Gauss Süreçleri, Eş Aralıklı Regresyon, Doğrusal Regresyon, Yapay Sinir Ağı, Basit Doğrusal Regresyon, Karar Destek Vektörleriyle Regresyon, Ibk, KStar, Toplamsal Regresyon ile Torbalama algoritmaları; WEKA [29] programlama aracı kullanılarak denenmiştir.

4.2.1 Zero Rule

Zero Rule algoritması bir veri kümesindeki varsayılan hatayı ölçmek için kullanılır. Zero Rule, test örneklerin hepsi için aynı değeri çıkış olarak verir. Bu değer tüm eğitim örneklerinin çıkışlarının ortalamasıdır. Buna göre Zero Rule'un ortalama karesel hatasının karekökü (RMSE) (4.5) eşitliği ile hesaplanır.

$$RMSE_{ZeroRule} = \sqrt{\frac{1}{N} \sum_{i=1}^N (y^m - y_{gercek}^i)^2}, \quad y^m = \frac{1}{T} \sum_{j=1}^T y_{gercek}^j \quad (4.5)$$

Eşitlikte y_{gercek}^j : j. eğitim örneğinin çıkış değerini, T: eğitim örneklerinin sayısını, N: test örneklerinin sayısını göstermektedir.

Bu çalışmada Zero Rule değeri, veri modellemesinin başarımında referans noktası olarak düşünülmüş; sadece bu değerden daha düşük hataya sahip modeller başarılı olarak değerlendirilmiştir.

4.2.2 M5 Kuralları (M5 Rules)

Quinlan [30] tarafından geliştirilen, yapraklarında lineer modeller bulunan bir regresyon ağacı algoritmasıdır. Veri kümesi yine uzayda alt kümelerle bölünür ve her bir alt uzaya bir model atanır. Alt uzayların sınırları bulunurken örneklerin çıkışlarının standart sapmasını (SDR) en fazla azaltan özellik-değer ikilisi kullanılmaktadır. SDR'si (4.6) en fazla olan özellik-değer ikilisi (i, θ) karar düğümüne yerleştirilir.

$$SDR(i, \theta) = sd(X_i) - \sum_{i \in \{+, -\}} \frac{|X_i^h|}{|X_i|} sd(X_i^h) \quad (4.6)$$

X_i : X veri kümesinin i. özelliklerinin değerleri


X_i^+ : X veri kümesinin i. özelliği θ eşik değerinden büyük olanlarının değerleri

X_i^- : X veri kümesinin i. özelliği θ eşik değerinden küçük olanlarının değerleri


$sd(K)$: K değerlerinin standart sapması

$|K|$: K kümesinin eleman sayısı

Şekil 4.5 ve 4.6'da [31] örnek bir M5 model ağacı ve alt uzayları görülmektedir.



Şekil 4.5 Örnek bir M5 model ağacının alt uzay sınırları [31]



Şekil 4.6 Örnek bir M5 model ağacı [31]

4.2.3 Karar Tablosu (Decision Table)

Karar ağaçlarına alternatif olarak Kohavi [32] tarafından önerilmiştir. Karar Tablosu algoritması önce tüm özellikler içinden Wrapper (durum uzayında arama) yöntemiyle özellik seçimi yapmaktadır. Boş bir küme olarak başlayan seçilmiş özellikler kümesine her bir adımda, en iyi başarıyı getirecek bir özellik eklenmektedir. Seçilen özelliklerin kaç tane olacağı algoritmanın bir parametresidir. Seçilen özellikler belirlendikten sonra karar tablosunu oluşturmak için özellikler, özellik-aralık ikililerine bölünmektedir. Bu ikililerin birleştirilmesiyle oluşturulan kuralların etiketleri olarak da bu kurallara uyan eğitim örneklerinin çıkış değerleri (sınıflandırma problemleri için en fazla olan sınıf, regresyon problemleri için çıkışların ortalaması) kullanılmaktadır.

4.2.4 Birleşik Kural (Conjunctive Rule)

Bu algoritma, Karar Tablolarının tek satırlı hali gibi görülebilir. Çıkış olarak birbirine 've' lerle bağlanmış özellik-eşik ikililerinden oluşan tek bir kural üretmektedir. Dolayısıyla






sınıflandırma problemleri için sadece iki sınıfı birbirinden ayırmaktadır. Regresyon problemleri içinse tüm test örnekleri için Zero Rule gibi tek bir değer üretmektedir.

4.2.5 REP Ağacı (REP Tree)

Hızlı bir regresyon ağacı algoritmasıdır. Sınıflandırma ağaçlarında genel olarak her boyutta karar sınırının geçebileceği en uygun değer, sınıflandırma başarısına göre aranır. Regresyon ağaçlarında ise karar, sınırı bölünen iki bölgeden geçirilecek fonksiyonların ortalama karesel hata toplamalarının minimum olmasına göre aranır (Breiman vd. [33]). Ağacın yapraklarındaki modellerin hata değerleri belirli bir eşik değerinin altına düşene dek, ağacın büyütülmesine (uzayın alt uzaylara bölünmesine) devam edilir. Yapraklarda sabit bir sayı yer almaktadır.

Çizelge 4.1’de [34] tek özellikli bir veri kümesinde farklı hata eşik değerleri için oluşturulmuş çeşitli regresyon ağaçları ve sonuçları verilmiştir. Bir yapraktaki hata bulunurken, o yapraktaki örneklerin çıkış değerlerinin ortalamalarına olan karesel uzaklıklarının toplamı kullanılmıştır. Çizelge 4.1 incelendiğinde, ağaçların yapraklarındaki hata değerinin azaldıkça ağacın büyüklüğünün arttığı görülmektedir. REP Ağacı algoritmasında ağaç oluşturulduktan sonra aşağıdan yukarı yönde budama işlemi gerçekleştirilir.

Çizelge 4.1 Farklı hata eşikleri için oluşturulmuş regresyon ağaçları ve çıktıları [34]

Yapraklardaki hata	Üretilen modelin çıkışı	Regresyon ağacı
Çok		
Orta		
Az		

4.2.6 Gauss Süreçleri (Gaussian Processes)

Giriş örnekleri üzerinde çeşitli kernel fonksiyonları tanımlayıp, bunların ağırlıklı toplamlarıyla çıkışı oluşturma sürecidir (Mackay [35]). Çıkış fonksiyonu (4.7) eşitliği ile hesaplanır.

$$f(x) = \sum_{j=1}^H w_j \phi_j(x) = w^T \phi(x) \quad (4.7)$$

(4.7) eşitliğinde, $\phi(x)$: giriş verisi üzerinde tanımlı bir kernel fonksiyonu, w : fonksiyonların ağırlıkları, H : kernel fonksiyonu sayısını göstermektedir.

Önceden belirlenmiş kernel fonksiyonları üzerinden, ağırlıkların bulunması işlemi (4.8) eşitliğindeki fonksiyonun minimizasyon optimizasyonu ile gerçekleştirilir.

$$J(w) = \frac{1}{2} \sum_{i=1}^N (w^T \phi(x_i) - y_i)^2 + \frac{\lambda}{2} w^T w \quad (4.8)$$

(4.8) eşitliğinde, y_i : i . örneğin gerçek çıkış değeri, λ : regularizasyon parametresi, N : eğitim setindeki örnek sayısıdır.

Kernel fonksiyonları olarak Radyal Tabanlı fonksiyonlar kullanılmıştır. Bu fonksiyonlar giriş verisinin bir noktaya olan uzaklığına göre gauss seklinde bir çıkış üretirler.

4.2.7 Eş Aralıklı Regresyon (Isotonic Regression)

Her özellik için eş aralıklı alt uzaylar oluşturup bunların her biri için çıkış olarak sabit bir sayı üretir (Best ve Chakravarti [36]). Çıkışı o özelliğin o aralığına düşen eğitim örneklerinin ortalamasını alarak bulur. Her özellik için bir model ürettikten sonra bu modellerden en düşük karesel hataya sahip olanını sonuç model olarak seçer. Sonuç modelde bir özellik ve bu özelliğe ait aralıklar ve çıkış değerleri yer alır.

4.2.8 Doğrusal Regresyon (Linear Regression)

Algoritma öncelikle bütün özelliklerin yer aldığı Eşitlik 4.9 tarzında bir doğrusal model üretir. Sonuç modelde ise özelliklerin bir kısmı yer alır. Sonuç modelde yer alan özelliklerin seçimi için, her bir adımda en küçük katsayısı olan özelliğin çıkarılmasıyla elde edilen modelin Akaike [37] bilgi kriterine göre önceki modele kıyasla daha başarılı olup olmadığına bakılır. Daha başarılı bir model bulunmadığında eleme işlemine son verilir.

$$y = w_0 + w_i x_i + \varepsilon \quad (4.9)$$


Akaike bilgi kriteri (AIC) (4.10) eşitliği yardımıyla belirlenir.

$$AIC = 2k + N * \ln(RSS / N) \quad (4.10)$$

(4.10) eşitliğinde, k: modeldeki parametre sayısını, RSS: karesel hataların toplamını, N: eğitim örneklerinin sayısını göstermektedir.

4.2.9 Yapay Sinir Ağı (Multilayer Perceptron)

Canlıların sinir hücrelerinden ilham alınarak oluşturulmuş modellerdir (Lippmann [38]). Şekil 4.7’de 4 girişi (4 özelliğe sahip bir veri kümesi için uygun), gizli katmanında 5 nöronu, 2 çıkışı olan bir sinir ağı gösterilmiştir.



Şekil 4.7 Örnek birçok katmanlı algılayıcı

Giriş nöronları kendilerine gelen bilgiyi bir sonraki katmandaki (saklı katman) nöronlara iletmenin dışında bir işlem yapmazlar. Saklı katman nöronları, giriş katmanından aldıkları bilgileri ağırlıklandırarak toplar ve bir fonksiyondan geçirip bir sonraki katmandaki (çıkış katmanı) nöronlara iletirler. Çıkış nöronları ise saklı katmandan aldıkları bilgileri ağırlıklandırarak toplar ve bir fonksiyondan geçirip ağın çıkışı üretirler.

Ağın eğitimi; başlangıçta rastgele seçilen nöronlar arası bağların ağırlıklarının, her bir eğitim örneğinin ağa sunularak iteratif olarak değiştirilmesiyle gerçekleştirilir.

Saklı ve çıkış katmanlarındaki nöronların çıkış değerleri (4.11) eşitliği ile hesaplanır.

$$cikis_j = S\left(\sum_{i=0}^m w_{ij} x_i\right) \quad (4.11)$$

Eşitlikteki w_{ij} : j. nöronla bir önceki katmandaki i. nöron arasındaki bağlantının ağırlığıdır. S fonksiyonu ise (4.12) eşitliğinde verilmiştir.

$$S(a) = 1 / (1 + \exp^{-a}) \quad (4.12)$$

Test aşamasında ağa bir örnek verildiğinde bu eşitlikler kullanılarak ağın çıkışı bulunur.

Eğitim aşamasında ise ağa bir eğitim örneği verildiğinde yine bu eşitliklerle ağın çıkışı bulunur. Daha sonra bu eğitim örneği için ağın çıkışı ve gerçek çıkış değerleri arasındaki farklar kullanılarak nöronlar arasındaki ağırlıkların değerleri gerçek çıkışa yaklaşan değerler üretecek şekilde değiştirilir.

Eğitim işleminde ağın çıkışları (çıkış katmanındaki nöronların çıkışları) bulunduktan sonra bu katmandaki her bir nöron için hata değeri (E_j) (4.13) eşitliğindeki gibi hesaplanır.

$$E_j = (d_j - a_j) a_j (1 - a_j) \quad (4.13)$$

(4.13) eşitliğindeki d_j : j. çıkış nöronunun eğitim etiketlerine göre olması gereken değerini, a_j ise j. çıkış nöronunun mevcut çıkışını göstermektedir. Çıkış katmanındaki nöronların hataları bulunduktan sonra bunlar kullanılarak saklı katmandaki nöronların hata değerleri (4.14) eşitliğindeki gibi hesaplanır.

$$E_i = a_i(1 - a_i) \sum_j E_j w_{ij} \quad (4.14)$$

(4.14) eşitliğinde, E_i : saklı katmanın i. nöronunun hatasını, E_j : çıkış katmanının j. nöronunun hatasını, w_{ij} : bu ikisi arasındaki bağlantının ağırlığını, a_i : saklı katmanın i. nöronunun çıkışını göstermektedir.

Ağdaki tüm (giriş katmanındakiler hariç) nöronlara ait hata değerleri bulunduktan sonra, ağırlıkların güncellenmesi (4.15) eşitliğine göre yapılır.

$$w_{ij}(t) = w_{ij}(t-1) + \Delta w_{ij}(t) \quad (4.15)$$

(4.15) eşitliğinde, w_{ij} : giriş ya da saklı katmandaki i. nöronla saklı ya da çıkış katmanındaki j. nöronun bağlantısını göstermektedir. Diğer bir ifadeyle her nöronun kendinden önceki katmandaki nöronlarla olan bağlantı ağırlığının güncellenmesi aynı metotla yapılır. Bağlantının ağırlığının üzerine (4.16) eşitliği ile bulunan değer eklenir.

$$\Delta w_{ij}(t) = -n_t E(w_{ij}(t)) + m \Delta w_{ij}(t-1) \quad (4.16)$$

4.16 eşitliğinde, n_t : t. andaki öğrenme katsayısını, m: momentum katsayısını ifade etmektedir. Öğrenme katsayısı $t=1$ için bir değer olarak seçilir ve her yeni eğitim işlemi tekrarında (epok) azaltılır. Momentum terimi ise, her güncelleme işlemine bir önceki adımda yapılan güncelleme işleminin etkisini ifade eder.

Eğitim setindeki her bir örnek için bu güncelleme işleminin tamamlanmasına epok adı verilmektedir. Ağın eğitimi için kaç epokun kullanılacağı kullanıcının seçiminde olan bir parametredir.

4.2.10 Basit Doğrusal Regresyon (Simple Linear Regression)

Veri kümesindeki her bir özellik için tek değişkenli bir regresyon modeli (4.17) oluşturulur.

$$y = wx + w_0 \quad (4.17)$$

(4.17) eşitliğinde, w tek bir katsayı, w_0 ise bias değeridir. w ve w_0 'ın bulunması en küçük kareler metoduyla yapılır. Bu işlem her özellik ile çıkış arasında düz bir çizgiden oluşan modeller üretir. Bu modellerden en düşük karesel hataya sahip olan sonuç modeli olarak verilir.

4.2.11 Karar Destek Vektörleriyle Regresyon (SMO Regression)

Karar Destek Vektörleri, AT&T Bell laboratuvarlarında Vapnik ve Cortes [39] tarafından geliştirilmiştir. İlk başta sınıflandırma problemleri için geliştirilen bu yöntem daha sonra regresyon problemlerine de uyarlanmıştır (Shevade vd. [40]; Smola ve Schoelkopf [41]). Bu yöntem, sınıflandırma problemleri için iki boyutta iki sınıfı birbirinden ayıran en kalın bölgenin bulunup, bu bölgenin ortasının da karar sınırı olarak belirlenmesi şeklinde özetlenebilir. Regresyon problemleri için ise, iki boyutta tüm eğitim kümesini içine alan en yatay bölgenin belirlenmesi şeklinde düşünülebilir. Bu bölgenin bulunması için :

Verilen d boyutlu, N örnekli bir eğitim seti için $(x_i, y_i)_{1 \leq i \leq N}, x \in \mathbb{R}^d, y \in \mathbb{R}$, karar destek vektörleriyle lineer regresyon (4.18) eşitliğindeki fonksiyonu bulmaya çalışır.

$$f(x) = wx + b \quad (4.18)$$

Bu fonksiyonu bulmak için de (4.19) eşitliğindeki optimizasyon problemini minimize eder.

$$\frac{1}{2} \|w\|^2 + C \sum_{i=1}^N Q(y_i - f(x_i)) \quad (4.19)$$

Optimizasyon probleminin ilk bileşeni w üzerinde (küçük w 'ler daha yatay fonksiyon üretir), ikinci bileşeni ise hata üzerinde minimizasyon yapar.

4.2.12 Örnek Tabanlı Algoritmalar (Ibk ve KStar)

Herhangi bir eğitim işlemine ihtiyaç duymayan algoritmalarıdır. Örnek tabanlı algoritmaların temel kabulleri, benzer örneklerin benzer çıkışlara sahip olduğudur. Bir test örneğinin çıkışı, o örneğe en benzeyen eğitim örneklerinin çıkışları kullanılarak

bulunur. Bu işlem iki alt seçim içerir. Birincisi örneklerin birbirlerine benzerliklerinin nasıl bulunacağı, ikincisi ise test örneğine benzer eğitim örneklerinin çıkışlarının nasıl birleştirileceğidir.

K en yakın komşu algoritması, kullanıcıdan test örneğine en yakın kaç eğitim örneğinin kullanılacağını ifade eden K değerini alır, örneklerin benzerliklerini Öklid ölçütüne göre belirler ve çıkışları en yakın K örneğin çıkışlarının ortalamasını alarak bulur. Sınıflandırma için kullanılıyorsa K adet eğitim örneğinin en çok dahil olduğu sınıfı test örneğinin sınıfı olarak belirler. Regresyon için kullanılıyorsa K adet eğitim örneğinin çıkışlarının ortalamasını test örneğinin çıkışı olarak belirler.

En yakın komşu algoritması bu alandaki ilk algoritmadır ve test örneğine sadece en benzeyen eğitim örneğini kullanarak ($K=1$) işlem yapar (Cover ve Hart [42]).

Literatürde, örnek tabanlı algoritmaların birçok versiyonu mevcuttur. Depolama maliyetini azaltmak ve gürültülü veri kümelerinde daha iyi sonuçlar almak için tüm eğitim örnekleri yerine bir alt kümesinin kullanımı önerilmiştir (Hart [43] ve Gates [44]).

“Instance-based Learning Algorithms” adlı çalışmada (Aha ve Kibler [45]) tüm özelliklerin skalasını eşitleyerek her bir özelliğin sonuç üzerindeki etkileri eşitlenmiştir. Daha sonra tüm örnekler yerine sadece yanlış sınıflandırılan örneklerin depolanması önerilmiştir.

Kstar algoritması ise, örnek benzerliğinde entropiyi kullanır. Her bir özellik için benzerlikleri (birinden diğerine rastgele dönüşüm olasılığı) ayrı ayrı bulur ve özelliklerin sonuçlarını birleştirirken olasılıklarının çarpımını kullanır. Dönüşüm işlemi için önceden tanımlanmış operatörler mevcuttur (Cleary ve Trigg [46]).

4.2.13 Toplamsal Regresyon (Additive Regression)

AdaBoost algoritmasının regresyon problemlerine uyarlanmasıdır [47]. Her bir iterasyondaki regresörünü bir önceki algoritmanın başarılı olamadığı kısımlara yoğunlaştıran bir meta algoritmadır. Her bir iterasyonda üretilen regresör sonuçlarını birleştirerek çıkışı verir.

Bu metotta bir regresörün ağırlığı (komite kararına etkisi) kendi hata değeriyle belirlenir. Diğer bir ifadeyle performansı yüksek olan algoritmaların kararlarına, düşük olanlardan daha fazla önem (ağırlık) verilir. Regresörlerin eğitildiği eğitim kümelerinin oluşturulması işleminde Torbalama'dan ayrılmaktadır. Torbalama'da tüm örneklerin eğitim kümesine seçilme şansı eşittir. Adaboost'ta ise önceki regresörler tarafından hatalı tahmin edilmiş bir örneğin seçilme olasılığı diğerlerinden yüksektir. Bu, ilk regresörlerin çıktıları kolaylıkla tahmin edilebilen örneklerle, sonrakilerin ise zor olan örneklerle yoğunlaşmasını sağlamaktadır (Freund ve Schapire [48]).

Algoritmada kullanılan semboller:

Veri kümesi $A = \{X_j, C_j\}_{j=1}^N, X_j \in \mathbb{R}^p$

$j \rightarrow$ örnek indisi

$L \rightarrow$ komitedeki regresör sayısı

$l \rightarrow$ regresör indisi

$H(x_j) \rightarrow$ j. örneğin H regresörüne göre çıkışı

AdaBoost algoritması :

- Örneklerin eğitim kümesine seçilme ağırlıklarına (sw) ilk değerlerini ata (hepsi eşit) (4.20).

$$sw_1(j) = 1/N, j = 1, \dots, N \quad (4.20)$$

- L adet regresör oluştur.
- Döngü $l=1, \dots, L$:
 - sw_l ağırlıklarına göre veri kümesinden eğitim kümesi A_l oluştur.
 - A_l kümesi üzerinde H_l regresörünü eğit.
 - H_l regresörünün tüm veri kümesi (A) üzerindeki ağırlıklı hatasını (e_l) RMSE ile bul. Burada seçilme olasılığı yüksek olan, (daha önceki regresörlerin iyi tahmin edemediği) örneklerde yapılan hatanın etkisi, diğer örneklerle göre daha fazla oluyor.

- Eğer $e_l > \varepsilon$ ise tüm sw' leri ilk değerlerine ata ve döngünün başına dön.
- Regresörlerin önem derecelerini (α_l) hatalarına bağlı olarak hesapla (4.21).

$$\alpha_l = 0.5 \ln \frac{1 - e_l}{e_l} \quad (4.21)$$

- Örneklerin seçilme ağırlıklarını güncelle (4.22):

$$sw_j^{(l+1)} = \frac{sw_j^{(l)}}{Z_l} * \begin{cases} \exp^{-\alpha_l} & \text{if } H_l(x_j) = C_j \\ \exp^{\alpha_l} & \text{if } H_l(x_j) \neq C_j \end{cases} \quad (4.22)$$

Z_l , normalizasyon katsayısıdır. $sw_j^{(l+1)}$ 'lerin toplamının 1 kalmasını sağlar.

AdaBoost ile oluşturulan L adet regresörün kararları önemleriyle ağırlıklandırılarak birleştirilir.

Adaboost'un yapısı sebebiyle, her bir regresör kendinden önceki regresörlerin deneyimlerinden faydalandığından regresörlerin paralel olarak oluşturulması mümkün değildir.

4.2.14 Torbalama (Bagging)

Breiman tarafından önerilmiştir (Breiman [49]). Torbalama'da N adet örnekten oluşan eğitim setinden yine N örnekleli bir eğitim seti yerine koymalı rastgele seçimle üretilir. Bu durumda bazı eğitim örnekleri yeni eğitim kümesinde yer almazken bazıları birden fazla kez yer alırlar. Topluluktaki her bir regresör bu şekilde üretilmiş birbirinden farklı örnekler içeren eğitim kümeleriyle eğitilirler ve sonuçları ortalama alarak birleştirilir.

UYGULAMA SONUÇLARI

Bu bölümde büyük bir bankanın operasyon merkezi süreçlerinin gelecekte nasıl gerçekleşeceğine dair modelleme sonuçları yer almaktadır.

5.1 Klasik Zaman Serisi Algoritmaları Kullanılarak Elde Edilen Sonuçlar

Bu bölümde ekonometrik modeller, Elman Ağ ve Markov Saklı Rejim Modeli kullanılarak elde edilen sonuçlar belirtilmiştir.

5.1.1 Ekonometrik Modeller Kullanılarak Elde Edilen Sonuçlar

Ekonometrik yöntemler yardımıyla işlem tiplerinin tahmininde kullanılan algoritmalar ve sonuçları Ek A'da belirtilmiştir. Ekte yer alan $AR(p,d)$, $MA(q,d)$, $ARIMA(p,q,d)$ algoritmalarındaki; p parametresi zaman serisinin p dereceden kendisinin gecikmesi ile ilişkisini, q parametresi hata terimlerinin geçmiş değerleri ile ilişkisini, d parametresi ise serinin d dereceden farkının alındığını ifade etmektedir.

AR modelinin p parametresi ve MA modelinin q parametresi için denenen değerler 1, 5, 10, 20, 30; d parametresi için denenen değerler ise 0 ve 1'dir. ARIMA modelinin parametre değerleri ise, AR ve MA algoritmalarındaki parametrelerin kombinasyonları kullanılarak belirlenmiştir. Buna göre, her bir işlem tipi için en iyi tahmini sağlayan ekonometrik model ve parametreleri Çizelge 5.1'de belirtilmiştir.

Sonuçlar incelendiğinde sadece AR ya da sadece MA modelini kullanmak yerine bu ikisinin birleşimi olan ARIMA modelini kullanmanın daha iyi sonuç verdiği görülmüştür. Ayrıca; yüksek değerdeki (20 ile 30) AR ve MA parametreleri daha iyi sonuç vermiştir. Bu durum için istisna olan işlem tipleri ise FAHES, GUMVR ve YDFON'dur. FHEFT ile

VRMAN ve MAASO ile VRMAN işlem tipleri için en iyi sonucu veren parametre değerleri aynıdır. En iyi modellenen işlem tipi REZVM, en kötü modellenen ise SSKTA'dır. Diğer taraftan serinin durağanlaştırılması için farkının alınması işlemi EFTOD, GUMVR, HABRM, MAASO, REZVM işlem tiplerinde daha iyi sonuç vermiştir.

Çizelge 5.1 Her bir işlem tipi için en iyi tahmini veren ekonometrik modeller

İşlem Tipi	Algoritma	Min. Hata
EFTOD	ARIMA(20,30,1)	0.0614
FAHES	ARIMA(1,20,0)	0.0809
FHEFT	ARIMA(20,20,0)	0.0424
FHVRH	ARIMA(10,20,0)	0.0633
GUMVR	ARIMA(5,5,1)	0.0729
HABRM	ARIMA(10,10,1)	0.0766
HVALE	ARIMA(10,30,0)	0.0506
MAASO	ARIMA(30,30,1)	0.0883
REZVM	ARIMA(30,30,1)	0.0252
SSKTA	AR(30,0)	0.128
VERGI	ARIMA(20,20,0)	0.0926
VRMAN	ARIMA(30,30,0)	0.0733
YDFON	AR(1,0)	0.1818

5.1.2 Elman Ağ Kullanılarak Elde Edilen Sonuçlar

Elman Ağ algoritmasının geçmiş gün parametresi 1, 5, 10, 20 değerleriyle ve saklı katmandaki nöron sayısı (SKN#) ise 5, 10, 20 değerleriyle denenmiş; Ek B'deki sonuçlar elde edilmiştir. Buna göre, her bir işlem tipi için en iyi sonucu veren Elman Ağ algoritması parametre değerleri Çizelge 5.2'de belirtilmiştir.

Sonuçlar incelendiğinde FAHES, VERGI, YDFON için 1 gün önceki; GUMVR, SSKTA için 5 gün önceki; EFTOD, FHEFT, HABRM, REZVM için 20 gün önceki ve FHVRH, HVALE,

VRMAN için ise 30 gün önceki geçmiş gün bilgisinin daha iyi sonuç verdiği görülmüştür. En iyi modellenen işlem tipi REZVM, en kötü modellenen ise YDFON'dur. Ekonometrik modellerle kıyaslandığında Elman Ağ algoritması FAHES, FHEFT, MAASO, SSKTA, VERGI işlem tiplerinde daha iyi sonuç vermiştir.

Çizelge 5.2 Her bir işlem tipi için en iyi tahmini veren Elman Ağ parametreleri

İşlem Tipi	Geçmiş Gün	SKN#	Min. Hata
EFTOD	20	20	0.0632
FAHES	1	5	0.0392
FHEFT	20	10	0.0411
FHVRH	30	5	0.071
GUMVR	5	10	0.0788
HABRM	20	20	0.0959
HVALE	30	5	0.052
MAASO	30	20	0.0706
REZVM	20	10	0.027
SSKTA	5	5	0.0868
VERGI	1	5	0.0454
VRMAN	30	10	0.0977
YDFON	1	10	0.1744

5.1.3 Markov Saklı Rejim Modeli Kullanılarak Elde Edilen Sonuçlar

Markov Saklı Rejim Modelinin geçmiş gün parametresi 1, 5, 10, 20, 30 değerleriyle ve durum sayısı parametresi ise 2, 3 değerleriyle denendi; Ek C'deki sonuçlar elde edildi. Buna göre, her bir işlem tipi için en iyi sonucu veren Markov Saklı Rejim Modelinin parametre değerleri Çizelge 5.3'de belirtilmiştir.

Sonuçlar incelendiğinde HABRM için 10 gün önceki; FAHES, FHEFT, GUMVR, HVALE, VRMAN için 20 gün önceki ve geriye kalan EFTOD, FHVRH, MAASO, REZVM, SSKTA,

VERGI, YDFON için ise 30 gün önceki geçmiş gün bilgisinin daha iyi sonuç verdiği görülmüştür. En iyi modellenen işlem tipi FHEFT, en kötü modellenen ise VRMAN'dır. Ekonometrik modellerle kıyaslandığında EFTOD, FAHES, FHVRH, SSKTA, VERGI, YDFON işlem tiplerinde daha iyi sonuç vermiştir. Elman Ağ ile kıyaslandığında ise EFTOD, FHVRH, SSKTA, YDFON işlem tiplerinde daha iyi sonuç vermiştir.

Çizelge 5.3 Her bir işlem tipi için en iyi tahmini veren Markov Saklı Rejim Modelinin parametreleri

İşlem Tipi	Geçmiş Gün	Durum Param.	Min. Hata
EFTOD	30	2	0.0558
FAHES	20	2	0.0802
FHEFT	20	3	0.0466
FHVRH	30	2	0.063
GUMVR	20	3	0.0931
HABRM	10	3	0.0963
HVALE	20	2	0.0559
MAASO	30	2	0.0936
REZVM	30	2	0.0618
SSKTA	30	2	0.0861
VERGI	30	2	0.0648
VRMAN	20	3	0.0992
YDFON	30	2	0.0558

5.2 Makine Öğrenmesi Algoritmaları Kullanılarak Elde Edilen Sonuçlar

Çalışmada kullanılan makine öğrenmesi algoritmaları Çizelge 5.4'de listelenmiştir.

Çizelge 5.4 Kullanılan makine öğrenmesi algoritmaları

Algoritma #	Algoritma Adı	Algoritma #	Algoritma Adı
1	ZeroRule	9	Yapay Sinir Ağı
2	M5 Kuralları	10	Basit Doğrusal Regresyon
3	Karar Tablosu	11	Karar Destek Vektörleriyle Regresyon
4	Birleşik Kural	12	lbc
5	REP Ağacı	13	Kstar
6	Gauss Süreçleri	14	Toplamsal Regresyon
7	Eş Aralıklı Regresyon	15	Torbalama
8	Doğrusal Regresyon		

5.2.1 Giriş Verisinin İfade Edilme Türleri


Makine öğrenmesi algoritmalarını kullanırken giriş verisinin ifade edilmesinde üç temel öge kullanılmıştır. Bu ögeler ve açıklamaları aşağıda verilmiştir:

- Tahmin edilecek güne ait hangi ek bilgilerin kullanılacağı: Bu öge; tahminlerde haftalık, aylık vb. şablonlardan faydalanabilmek için kullanılmıştır. Tatil tipi özelliği dışındaki diğer tüm özellikler nümeriktir. Bir güne ait kullanılan ek özellikler aşağıda verilmiştir :
 - Yılı
 - Yılın kaçınıcı ayı
 - Ayın kaçınıcı günü
 - Tatil tipi : Normal iş günü, hafta sonu, yarım gün resmi tatil, tam gün resmi tatil
 - Yılın kaçınıcı çeyreği
 - Yılın kaçınıcı haftası
 - Yılın kaçınıcı günü

- Yılın kaçınıcı iş günü
- Ayın kaçınıcı haftası
- Ayın kaçınıcı iş günü
- Ayın son iş gününe kaç gün kaldığı
- Haftanın kaçınıcı günü
- Haftanın kaçınıcı iş günü
- (Eğer varsa) Resmi tatile kaç iş günü kaldığı
- (Eğer varsa) Resmi tatil sonrası kaçınıcı iş günü olduğu
- (Eğer varsa) Kendisinden sonra gelen resmi tatilin süresi
- (Eğer varsa) Kendisinden önceki resmi tatilin süresi
- Geçmiş hangi günlerin giriş olarak kullanılacağı: Bu ögenin alabileceği değerler aşağıda sıralanmıştır.
 - NONE : Geçmiş hiçbir veri kullanılmayacak.
 - MAX_WEEKDAY_DISTANCE : Geçmiş X günlük veri tahminde kullanılacak.
 - WEEKDAY_BEFORE : Tahmin edilecek iş gününden X ve katları uzaklıktaki Y adet iş günü tahminde kullanılacak. Ayrıca, istenirse ilgili geçmiş günden önceki ve sonraki Z adet gün de kullanılacak.
 - MONTH_BEFORE : Tahmin edilecek iş gününden X ay önceki ve katları uzaklıktaki Y adet iş günü tahminde kullanılacak. Ayrıca, istenirse ilgili geçmiş günden önceki ve sonraki Z adet gün de kullanılacak.
 - SAME_BUSINESSDAY_OF_MONTH : Tahmin edilecek iş gününden X ay önceki aynı iş günü ve katları uzaklıktaki Y adet iş günü tahminde kullanılacak.
 - SAME_DISTANCE_TO_LAST_OF_MONTH : Ay sonuna olan uzaklığı, tahmin edilecek günün ay sonuna olan uzaklığı ile aynı olan; geçmiş X adet gün tahminde kullanılacak.

- Verinin geçmiş bir güne bağlı olarak ifade edilip edilmeyeceği (zaman farkı) : Seriyi dönemsel etkilerden arındırma için bu işlem (ya farkını ya da oranını alarak) yapıldı. Bu öğenin alabileceği değerler aşağıda sıralanmıştır :
 - NONE : Veri kendisinden önceki bir güne bağlı olarak ifade edilmeyecek.
 - WEEKDAY : Veri kendisinden X önceki güne (farksal veya oransal) bağlı olarak ifade edilecek.
 - MONTH : Veri kendisinden X ay önceki güne (farksal veya oransal) bağlı olarak ifade edilecek.

Bu öğelerin çeşitli kombinasyonları kullanılarak verinin farklı gösterim şekilleri (senaryolar) üretilmiştir. Ayrıca; senaryoların üretimi elle yapılırsa çok zaman alacağından, bu işlem için .NET'te genel bir program yazılarak işlem otomatikleştirilmiştir. Böylece; senaryoların oluşturulması, yeni bir senaryo eklenmesi ya da mevcut senaryoda güncelleme yapılması çok kolaylaşmıştır. Yazılan .NET programına ilişkin ekran görüntüsü Şekil 5.1'de yer almaktadır.



Şekil 5.1 Senaryo üretici .NET programı

5.2.2 Denenecek Senaryoların Oluşturulma Adımları

Denenecek senaryolar 5 adımda oluşturuldu :

1. **Adım** : Çizelge 5.5’de belirtilen geçmiş gün kuralları kullanılarak; her bir işlem tipi için 1.adım senaryoları oluşturulmuş ve Çizelge 5.4’de belirtilen 15 algoritma üzerinde denenerek her bir senaryo için minimum hatayı veren algoritma ve hata değeri bulunmuştur.

Çizelge 5.5 1.adımda oluşturulan senaryolar

Geçmiş Gün Kuralı	Açıklama	Senaryo #
1 MAX_DAY_DISTANCE	Geçmiş 1 günlük veri	1
5 MAX_DAY_DISTANCE	Geçmiş 5 günlük veri	2
10 MAX_DAY_DISTANCE	Geçmiş 10 günlük veri	3
20 MAX_DAY_DISTANCE	Geçmiş 20 günlük veri	4
30 MAX_DAY_DISTANCE	Geçmiş 30 günlük veri	5
60 MAX_DAY_DISTANCE	Geçmiş 60 günlük veri	6
5 WEEKDAY_BEFORE (repeatCount = 5)	Geçmiş 5. gün ve katları uzaklıktaki 5 adet veri	7
5 WEEKDAY_BEFORE (backwardDayCount=-1, repeatCount=5)	Geçmiş 5. gün ve katları uzaklıktaki 5 adet veri ve her ilgili geçmiş günden 1 gün öncesi	8
20 WEEKDAY_BEFORE (repeatCount= 5)	Geçmiş 20. gün ve katları uzaklıktaki 5 adet veri	9
20 WEEKDAY_BEFORE (backwardDayCount=-1, repeatCount=5)	Geçmiş 20. gün ve katları uzaklıktaki 5 adet veri ve her ilgili geçmiş günden 1 gün öncesi	10
20 WEEKDAY_BEFORE (backwardDayCount=-2, repeatCount=5)	Geçmiş 20. gün ve katları uzaklıktaki 5 adet veri ve her ilgili geçmiş günden 2 gün öncesi	11
1 MONTH_BEFORE (repeatCount=5)	Geçmiş 1 ay önceki gün ve katları uzaklıktaki 5 adet veri	12

Çizelge 5.6 1.adımda oluşturulan senaryolar (devam)

Geçmiş Gün Kuralı	Açıklama	Senaryo #
1 MONTH_BEFORE (backwardDayCount=-1, repeatCount=5)	Geçmiş 1 ay önceki gün ve katları uzaklıktaki 5 adet veri ve her ilgili geçmiş günden 1 gün öncesi	13
1 MONTH_BEFORE (backwardDayCount=-2, repeatCount=5)	Geçmiş 1 ay önceki gün ve katları uzaklıktaki 5 adet veri ve ayrıca ilgili geçmiş günden 2 gün öncesi	14
3 MONTH_BEFORE (repeatCount=2)	Geçmiş 3 ay önceki gün ve katı uzaklıktaki 2 adet veri	15
3 MONTH_BEFORE (backwardDayCount=±2, repeatCount=2)	Geçmiş 3 ay önceki gün ve katı uzaklıktaki 2 adet veri ve her ilgili geçmiş günden 2 gün öncesi ve 2 gün sonrası	16
SAME_BUSINESSDAY_OF_MONT H (repeatCount=1)	Geçmiş 1 ay önceki aynı iş günü	17
SAME_BUSINESSDAY_OF_MONT H (repeatCount=3)	Geçmiş 1 ay önceki aynı iş günü ve katları uzaklıktaki 3 adet veri	18
SAME_BUSINESSDAY_OF_MONT H (repeatCount=6)	Geçmiş 1 ay önceki aynı iş günü ve katları uzaklıktaki 6 adet veri	19
SAME_DISTANCE_TO_LAST_OF_ MONTH (repeatCount=1)	Ay sonuna uzaklığı aynı olan geçmiş 1 ay önceki güne ait veri	20
SAME_DISTANCE_TO_LAST_OF_ MONTH (repeatCount=3)	Ay sonuna uzaklığı aynı olan geçmiş 1 ay önceki gün ve katları uzaklıktaki 3 adet veri	21
SAME_DISTANCE_TO_LAST_OF_ MONTH (repeatCount=6)	Ay sonuna uzaklığı aynı olan geçmiş 1 ay önceki gün ve katları uzaklıktaki 6 adet veri	22

2. Adım : 1. adım senaryolarından minimum hatayı veren (en iyi) ilk üç senaryo seçilmiş ve bu senaryolardaki geçmiş gün kurallarının 2’li ve 3’lü kombinasyonları kullanılarak 2. adım senaryoları üretilmiştir (Senaryoların 2.adım senaryoları olduğunu belirtmek için, senaryo numaraları 100’den başlanarak verilmiştir).

3. Adım : Her bir işlem tipi için; 1. adım ve 2. adımda oluşturulan senaryolardan minimum hatayı veren en iyi ilk dört senaryo seçilmiş ve bu senaryolara Çizelge 5.6'da belirtilen 10 adet zaman farkı seçenekleri uygulanmıştır (Senaryoların 3.adım senaryoları olduğunu belirtebilmek için, senaryo numaraları 300'den başlanarak verilmiştir).

Çizelge 5.7 Senaryo oluşturma 3.adım zaman farkı seçenekleri

Zaman Farkı	Açıklama
1 WEEKDAY DIFFERENCE	Veri kendisinden 1 gün önceki günden çıkarılarak ifade edilecek
5 WEEKDAY DIFFERENCE	Veri kendisinden 5 gün önceki günden çıkarılarak ifade edilecek
20 WEEKDAY DIFFERENCE	Veri kendisinden 20 gün önceki günden çıkarılarak ifade edilecek
1 WEEKDAY RATIO	Veri kendisinden 1 gün önceki güne bölünerek ifade edilecek
5 WEEKDAY RATIO	Veri kendisinden 5 gün önceki güne bölünerek ifade edilecek
20 WEEKDAY RATIO	Veri kendisinden 20 gün önceki güne bölünerek ifade edilecek
1 MONTH DIFFERENCE	Veri kendisinden 1 ay önceki günden çıkarılarak ifade edilecek
3 MONTH DIFFERENCE	Veri kendisinden 3 ay önceki günden çıkarılarak ifade edilecek
1 MONTH RATIO	Veri kendisinden 1 ay önceki güne bölünerek ifade edilecek
3 MONTH RATIO	Veri kendisinden 3 ay önceki güne bölünerek ifade edilecek

4. Adım : İlk üç adım sonucundaki en iyi senaryo-algoritma ikilisi için algoritmanın parametrelerinde değişiklik yapılarak daha iyi sonuç elde edilmeye çalışılmıştır.

5. Adım : 4. adım sonucu elde edilen en iyi senaryo-algoritma ikilisi için, Weka'da [29] mevcut ve veriye uygulanabilir olan CfsSubsetEval, ClassifierSubsetEval, LatentSemanticAnalysis, Principal Components, ReliefAttributeEval ve WrapperSubsetEval özellik azaltma algoritmaları uygulanarak daha iyi sonuç elde edilmeye çalışılmıştır.

Sonuç olarak; bu beş adımda denenilen senaryo-algoritma ikililerinden minimum hatayı veren en iyi ikili, ilgili işlem tipini tahmin etmede kullanılacak model olarak seçilmiştir.

5.2.3 EFTOD İşlem Tipi İçin Tahminde Kullanılacak Makine Öğrenmesi Modelinin (Senaryo-Algoritma İkili) Belirlenmesi

1. Adım

Çizelge 5.5'deki 23 adet 1.adım senaryosu Çizelge 5.4'deki 15 algortmada denenmiş; her bir senaryo için minimum hatayı veren algoritma ve hata değeri belirlenmiştir (Ek D). Buna göre minimum hatayı veren ilk 3 model (senaryo-algoritma ikilisi) Çizelge 5.7'de belirtilmiştir.

Çizelge 5.8 EFTOD işlem tipi için 1.adımda minimum hatayı veren ilk 3 model

Senaryo #	Alg. #	Geçmiş Gün Kuralı	Min. Hata
1	14	Geçmiş 1 günlük veri	0.0326
20	14	Ay sonuna uzaklığı aynı olan geçmiş 1 ay önceki güne ait veri	0.0328
9	14	Geçmiş 20. gün ve katları uzaklıktaki 5 veri	0.0346

2. Adım

1. adım sonucu seçilen 1, 20 ve 9 numaralı senaryolardaki geçmiş gün kurallarının ikili ve üçlü kombinasyonları kullanılarak, 2. adım senaryoları oluşturulmuş ve Çizelge 5.4'deki 15 algoritma üzerinde denenmiştir. Elde edilen sonuçlar Çizelge 5.8'de verilmektedir. Sonuçlara bakıldığında, 2.adımda oluşturulan senaryoların hiçbirinin 1. adımdaki senaryolardan daha iyi sonuç vermediği görülmüştür.

3.Adım

1. adım ve 2. adım senaryolarından minimum hatayı veren en iyi ilk 4 senaryo (1, 20, 9, 2) seçilerek, her bir senaryoya Çizelge 5.6'daki 10 adet zaman farkı seçeneği uygulanmıştır. Çizelge 5.9'da senaryo sütunundaki numaralar; temel senaryo sütunundaki numaralı senaryoya Çizelge 5.6'daki 10 adet zaman farkı seçeneğinin uygulanmasıyla elde edilen yeni senaryo numaralarını göstermektedir.

Çizelge 5.9 EFTOD işlem tipi için 2.adım sonuçları

Senaryo #	107 (1+20)	116 (9+20)	126 (1+9+20)	124 (1+9)
Alg. 1	0.1	0.1011	0.1011	0.1011
Alg. 2	0.0671	0.0988	0.0775	0.083
Alg. 3	0.0722	0.0656	0.0656	0.0656
Alg. 4	0.094	0.0781	0.0781	0.0781
Alg. 5	0.0598	0.0763	0.0727	0.0727
Alg. 6	0.0767	0.0786	0.0776	0.0824
Alg. 7	0.0944	0.0791	0.0791	0.0791
Alg. 8	0.1024	0.0849	0.0803	0.0824
Alg. 9	0.0901	0.0983	0.0921	0.0947
Alg. 10	0.0974	0.0911	0.0911	0.0911
Alg. 11	0.1056	0.0844	0.082	0.0845
Alg. 12	0.0937	0.0945	0.0848	0.1015
Alg. 13	0.0926	0.0936	0.0994	0.0922
Alg. 14	0.0371	0.0381	0.0457	0.0458
Alg. 15	0.0593	0.063	0.0647	0.0643
Min. Hata	0.0371	0.0381	0.0457	0.0458

Çizelge 5.10 EFTOD işlem tipi için 3. adım senaryoları

Senaryo #	Temel Senaryo #
250-259	20
270-279	1
330-339	2
370-379	9

Üretilmiş olan bu 40 zaman farklı senaryodan en başarılı ilk 3 tanesinin sonuçları Çizelge 5.10'da yer almaktadır.

Çizelge 5.11 EFTOD işlem tipi için en başarılı ilk üç 3. adım sonuçları

Senaryo #	273	333	253
Alg. 1	0.1155	0.1155	0.1211
Alg. 2	0.0698	0.0857	0.0885
Alg. 3	0.0766	0.0766	0.0856
Alg. 4	0.0931	0.0931	0.0988
Alg. 5	0.0637	0.0756	0.0833
Alg. 6	0.0797	0.0775	0.0894
Alg. 7	0.0927	0.0927	0.0979
Alg. 8	0.1012	0.0888	0.1084
Alg. 9	0.1958	0.1281	0.1061
Alg. 10	0.1033	0.1083	0.1088
Alg. 11	0.1034	0.0898	0.112
Alg. 12	0.0936	0.0898	0.0928
Alg. 13	0.1069	0.1174	0.1238
Alg. 14	0.0395	0.0404	0.0511
Alg. 15	0.0592	0.0623	0.0791
Min. Hata	0.0395	0.0404	0.0511

Buna göre, 3. adımdaki senaryoların da 1. adımdaki senaryolara göre daha iyi sonuç vermediği görülmüştür.

İlk üç adım sonucunda; EFTOD işlem tipini tahmin etmede minimum hatayı veren en iyi üç senaryo-algoritma ikilileri Çizelge 5.11'de yer almakta ve 14 numaralı algoritmanın üç senaryo için de en iyi sonucu veren algoritma olduğu görülmektedir.

Çizelge 5.12 EFTOD işlem tipi için 3.adım sonunda en başarılı ilk üç sonuç

Senaryo #	Alg. #	Geçmiş Gün Kuralı	Min. Hata
1	14	Geçmiş 1 günlük veri	0.0326
20	14	Ay sonuna uzaklığı aynı olan geçmiş 1 ay önceki güne ait veri	0.0328
9	14	Geçmiş 20. gün ve katları uzaklıktaki 5 adet veri	0.0346

4.Adım

En iyi sonucu veren senaryo1-algoritma14 ikilisi için; ilgili Toplamsal Regresyon algoritmasının parametrelerinde değişiklik yapılarak, daha iyi sonuç elde edilmiştir. Bunun için algoritmanın sınıflandırıcı özelliği torbalama (bagging) olarak değiştirilmiştir. Böylece minimum hata 0.0326 değerinden 0.0317 değerine düşürülmüştür.

5. Adım

En iyi sonucu veren 1 numaralı senaryoya özellik azaltma algoritmaları uygulanarak, 14 numaralı algoritma üzerinde çalıştırılmış; ancak 4. adıma göre daha iyi bir sonuç elde edilememiştir.

Sonuç olarak; EFTOD işlem tipini tahmin etmede minimum hatayı veren en iyi model 1 numaralı senaryo (geçmiş 1 günlük veri) ile 14 numaralı algoritma (Toplamsal Regresyon) ikilisidir. Toplamsal Regresyon algoritmasının sınıflandırıcı özelliği torbalama (bagging) olarak değiştirilmiştir. Minimum hata 0.0317 olarak alınmıştır.

5.2.4 FAHES İşlem Tipi İçin Tahminde Kullanılacak Makine Öğrenmesi Modelinin (Senaryo-Algoritma İkilisi) Belirlenmesi

1.Adım

Çizelge 5.5'deki 23 adet 1.adım senaryosu Çizelge 5.4'deki 15 algoritmada denenmiş; her bir senaryo için minimum hatayı veren algoritma ve hata değeri belirlenmiştir (Ek E). Buna göre minimum hatayı veren ilk 3 model (senaryo-algoritma ikilisi) Çizelge 5.12'de belirtilmiştir.

Çizelge 5.13 FAHES işlem tipi için 1.adımda minimum hatayı veren ilk 3 model

Senaryo #	Alg. #	Geçmiş Gün Kuralı	Min. Hata
12	5	Geçmiş 1 ay önceki gün ve katları uzaklıktaki 5 veri	0.0361
16	2	Geçmiş 3 ay önceki gün ve kati uzaklıktaki 2 adet veri ile her ilgili geçmiş günden 2 gün öncesi ve 2 gün sonrası	0.0391
2	3	Geçmiş 5 günlük veri	0.0399

2. Adım

1. adım sonucu seçilen 12, 16 ve 2 numaralı senaryolardaki geçmiş gün kurallarının ikili ve üçlü kombinasyonları kullanılarak, 2. adım senaryoları oluşturulmuş ve Çizelge 5.4'deki 15 algoritma üzerinde denenmiştir. Elde edilen sonuçlar Çizelge 5.13'da verilmektedir.

Sonuçlara bakıldığında; 110 numaralı senaryo ve algoritma 5 ikilisinin 1. adımdaki senaryolara kıyasla en iyi 2. minimum hatayı verdiği görülmüştür.

3. Adım

1. adım ve 2. adım senaryolarından minimum hatayı veren en iyi ilk 4 senaryo (12, 110, 16, 2) seçilerek, her bir senaryoya Çizelge 5.6'daki 10 adet zaman farkı seçeneği uygulanmıştır.

Çizelge 5.14'de senaryo sütunundaki numaralar; temel senaryo sütunundaki numaralı senaryoya Çizelge 5.6'daki 10 adet zaman farkı seçeneğinin uygulanmasıyla elde edilen yeni senaryo numaralarını göstermektedir.

Üretilmiş olan bu 40 zaman farklı senaryodan en başarılı ilk 3 tanesinin sonuçları Çizelge 5.15'de yer almaktadır. Buna göre, 3. adımdaki senaryoların ilk iki adımdaki senaryolara göre daha iyi sonuç verdiği görülmüştür.

Çizelge 5.14 FAHES işlem tipi için 2.adım sonuçları

Senaryo #	110 (2+12)	111 (2+16)	109 (12+16)	112 (2+12+16)
Alg. 1	0.1082	0.1112	0.1112	0.1112
Alg. 2	0.0817	0.0711	0.1257	0.0961
Alg. 3	0.1037	0.0965	0.0962	0.0965
Alg. 4	0.0942	0.0844	0.0874	0.0844
Alg. 5	0.0363	0.076	0.0727	0.0727
Alg. 6	0.0772	0.0639	0.0782	0.077
Alg. 7	0.071	0.0737	0.0668	0.0737
Alg. 8	0.1022	0.0753	0.1319	0.1422
Alg. 9	0.1377	0.0598	0.1135	0.1568
Alg. 10	0.0676	0.0688	0.0688	0.0688
Alg. 11	0.0621	0.074	0.0811	0.0871
Alg. 12	0.0745	0.0517	0.0525	0.0525
Alg. 13	0.1035	0.0688	0.0976	0.0974
Alg. 14	0.0578	0.0406	0.1181	0.1035
Alg. 15	0.0544	0.0594	0.0716	0.0629
Min. Hata	0.0363	0.0406	0.0525	0.0525

Çizelge 5.15 FAHES işlem tipi için 3. adım senaryoları

Senaryo #	Temel Senaryo #
330-339	2
480-489	12
490-499	110 (2+12)
500-509	16

Çizelge 5.16 FAHES işlem tipi için en başarılı ilk üç 3. adım sonuçları

Senaryo #	339	489	499
Alg. 1	0.0051	0.0059	0.0059
Alg. 2	0.0156	0.0104	0.0044
Alg. 3	0.0051	0.0059	0.0059
Alg. 4	0.0017	0.0019	0.0019
Alg. 5	0.0054	0.0055	0.0055
Alg. 6	0.0026	0.0032	0.0032
Alg. 7	0.0022	0.0019	0.0019
Alg. 8	0.0069	0.007	0.0123
Alg. 9	0.0059	0.003	0.0028
Alg. 10	0.0016	0.0018	0.0018
Alg. 11	0.0016	0.002	0.0019
Alg. 12	0.0019	0.002	0.002
Alg. 13	0.002	0.002	0.0018
Alg. 14	0.0034	0.0037	0.0029
Alg. 15	0.0041	0.0092	0.0073
Min. Hata	0.0016	0.0018	0.0018

İlk üç adım sonucunda; FAHES işlem tipini tahmin etmede minimum hatayı veren en iyi üç senaryo-algoritma ikilileri Çizelge 5.16'da yer almaktadır. Tablodan 10 numaralı algoritmanın (Simple Lineer Regression) üç senaryo için de en iyi sonucu veren algoritma olduğu görülmüştür. Ayrıca; verinin kendisinden 3 ay önceki güne bölünerek ifade edildiği zaman farkı seçeneğinin ilk üç senaryo için de geçerli olduğu bulunmuştur.

Çizelge 5.17 FAHES işlem tipi için 3.adım sonunda en başarılı ilk üç sonuç

Senaryo #	Alg. #	Geçmiş Gün Kuralı	Zaman Farkı Kuralı	Min. Hata
339	10	Geçmiş 5 günlük veri	Veri kendisinden 3 ay önceki güne bölünerek ifade edilecek	0.0016
489	10	Geçmiş 1 ay önceki gün ve katları uzaklıktaki 5 adet veri	Veri kendisinden 3 ay önceki güne bölünerek ifade edilecek	0.0018
499	10	Geçmiş 5 günlük veri + geçmiş 1 ay önceki gün ve katları uzaklıktaki 5 adet veri	Veri kendisinden 3 ay önceki güne bölünerek ifade edilecek	0.0018

4. Adım

En iyi sonucu veren senaryo339-algoritma10 ikilisi için; ilgili “Simple Linear” algoritmasının herhangi bir parametresi olmadığı için bu adımda herhangi bir işlem yapılamamıştır.

5. Adım

En iyi sonucu veren 339 numaralı senaryoya özellik azaltma algoritmaları uygulanarak, 10 numaralı algoritma üzerinde uygulanmış ve diğer adımlara göre daha iyi sonuç edilmiştir. Böylece minimum hata 0.0016 değerinden 0.0015 değerine düşürülmüştür.

Sonuç olarak; FAHES işlem tipini tahmin etmede minimum hatayı veren en iyi model 339 numaralı senaryo (geçmiş 5 günlük veri + veri kendisinden 3 ay önceki güne bölünerek ifade edilecek) ile 10 numaralı algoritma (Simple Lineer) ikilisidir. Ayrıca CfsSubsetEval algoritması kullanılarak, güne ait ek özelliklerden sadece MOD (yılın kaçınıcı ayı), BDDtoLBDOM (ayın son iş gününe kaç gün kaldığı) ile AHD (kendisinden önceki resmi tatilin süresi) özellikleri seçilmiştir. Minimum hata 0.0015 olarak elde edilmiştir.

5.2.5 FHEFT İşlem Tipi İçin Tahminde Kullanılacak Makine Öğrenmesi Modelinin (Senaryo-Algoritma İkili) Belirlenmesi

1.Adım

Çizelge 5.5'deki 23 adet 1.adım senaryosu Çizelge 5.4'deki 15 algoritmada denenmiş; her bir senaryo için minimum hatayı veren algoritma ve hata değeri belirlenmiştir (Ek F). Buna göre minimum hatayı veren ilk 3 model (senaryo-algoritma ikilisi) Çizelge 5.17'de belirtilmiştir.

Çizelge 5.18 FHEFT işlem tipi için 1.adımda minimum hatayı veren ilk 3 model

Senaryo #	Alg. #	Geçmiş Gün Kuralı	Min. Hata
17	14	Geçmiş 1 ay önceki aynı iş günü	0.0316
9	14	Geçmiş 20. gün ve katları uzaklıktaki 5 adet veri	0.0326
20	14	Ay sonuna uzaklığı aynı olan geçmiş 1 ay önceki güne ait veri	0.0334

2. Adım

1. adım sonucu seçilen 17, 9 ve 20 numaralı senaryolardaki geçmiş gün kurallarının ikili ve üçlü kombinasyonları kullanılarak, 2. adım senaryoları oluşturulmuş ve Çizelge 5.4'deki 15 algoritma üzerinde denenmiştir. Elde edilen sonuçlar Çizelge 5.18'de verilmektedir.

Sonuçlara bakıldığında, 2. adımda oluşturulan senaryoların hiçbirinin 1. adımdaki senaryolardan daha iyi sonuç vermediği görülmüştür.

3. Adım

1. adım ve 2. adım senaryolarından minimum hatayı veren en iyi ilk 4 senaryo (17, 9, 20, 8) seçilerek, her bir senaryoya Çizelge 5.6'daki 10 adet zaman farkı seçeneği uygulanmıştır.

Çizelge 5.19'da senaryo sütunundaki numaralar; temel senaryo sütunundaki numaralı senaryoya Çizelge 5.6'daki 10 adet zaman farkı seçeneğinin uygulanmasıyla elde edilen yeni senaryo numaralarını göstermektedir.

Çizelge 5.19 FHEFT işlem tipi için 2.adım sonuçları

Senaryo #	106 (17+20)	115 (9+17)	117 (9+17+20)	116 (9+20)
Alg. 1	0.1529	0.141	0.141	0.141
Alg. 2	0.0695	0.0746	0.1192	0.1203
Alg. 3	0.0456	0.0421	0.0421	0.0421
Alg. 4	0.0645	0.0677	0.0677	0.0677
Alg. 5	0.0469	0.067	0.0477	0.0477
Alg. 6	0.0878	0.0591	0.0603	0.0601
Alg. 7	0.0646	0.0671	0.0671	0.0671
Alg. 8	0.1386	0.0827	0.0814	0.0805
Alg. 9	0.0597	0.0779	0.069	0.0638
Alg. 10	0.125	0.0887	0.0887	0.0887
Alg. 11	0.1533	0.0712	0.0698	0.0706
Alg. 12	0.0844	0.0721	0.0782	0.0743
Alg. 13	0.1262	0.0492	0.0543	0.0512
Alg. 14	0.0345	0.0349	0.0366	0.0368
Alg. 15	0.0407	0.049	0.0463	0.0457
Min. Hata	0.0345	0.0349	0.0366	0.0368

Çizelge 5.20 FHEFT işlem tipi için 3. adım senaryoları

Senaryo #	Temel Senaryo #
240-249	17
250-259	20
310-319	8
370-379	9

Üretilmiş olan bu 40 zaman farklı senaryodan en başarılı ilk 3 tanesinin sonuçları Çizelge 5.20’de yer almaktadır.

Çizelge 5.21 FHEFT işlem tipi için en başarılı ilk üç 3. adım sonuçları

Senaryo #	318	253	250
Alg. 1	0.2098	0.1733	0.2181
Alg. 2	0.0557	0.0624	0.0649
Alg. 3	0.0445	0.0597	0.0592
Alg. 4	0.0762	0.0914	0.1326
Alg. 5	0.0549	0.07	0.0735
Alg. 6	0.0551	0.0834	0.1034
Alg. 7	0.0462	0.0682	0.0711
Alg. 8	0.0457	0.0919	0.0975
Alg. 9	0.0889	0.0747	0.0894
Alg. 10	0.0519	0.0956	0.1034
Alg. 11	0.0432	0.0942	0.0982
Alg. 12	0.0868	0.1043	0.1487
Alg. 13	0.0368	0.0979	0.1123
Alg. 14	0.0526	0.0407	0.0427
Alg. 15	0.0403	0.056	0.0553
Min. Hata	0.0368	0.0407	0.0427

Buna göre, 3. adımdaki senaryoların da 1. adımdaki senaryolara göre daha iyi sonuç vermediği görülmüştür.

İlk üç adım sonucunda; FHEFT işlem tipini tahmin etmede minimum hatayı veren en iyi üç senaryo-algoritma ikilileri Çizelge 5.21’de yer almaktadır. Tablodan 14 numaralı algoritmanın ilk üç senaryo için de en iyi sonucu veren algoritma olduğu görülmektedir.

Çizelge 5.22 FHEFT işlem tipi için 3.adım sonunda en başarılı ilk üç sonuç

Senaryo #	Alg. #	Geçmiş Gün Kuralı	Min. Hata
17	14	Geçmiş 1 ay önceki aynı iş günü	0.0316
9	14	Geçmiş 20. gün ve katları uzaklıktaki 5 adet veri	0.0326
20	14	Ay sonuna uzaklığı aynı olan geçmiş 1 ay önceki güne ait veri	0.0334

4. Adım

En iyi sonucu veren senaryo17 - algoritma14 ikilisi için; ilgili Toplamsal Regresyon algoritmasının parametrelerinde değişiklik yapılarak, daha iyi sonuç elde edilmiştir. Bunun için; algoritmanın sınıflandırıcı özelliği torbalama (bagging), daralma değeri 0.99 olarak değiştirilmiştir. Böylece minimum hata 0.0316 değerinden 0.0308 değerine düşürülmüştür.

5. Adım

En iyi sonucu veren 17 numaralı senaryoya özellik azaltma algoritmaları uygulanarak, 14 numaralı algoritma üzerinde uygulanmış; ancak 4. adıma göre daha iyi bir sonuç elde edilememiştir.

Sonuç olarak; FHEFT işlem tipini tahmin etmede minimum hatayı veren en iyi model 17 numaralı senaryo (geçmiş 1 ay önceki aynı iş günü) ile 14 numaralı algoritma (Toplamsal Regresyon) ikilisidir. Toplamsal Regresyon algoritmasının sınıflandırıcı özelliği torbalama (bagging), daralma değeri 0.99, iterasyon sayısı 100 olarak değiştirilmiştir. Minimum hata 0.0308 olarak alınmıştır.

5.2.6 FHVRH İşlem Tipi İçin Tahminde Kullanılacak Makine Öğrenmesi Modelinin (Senaryo-Algoritma İkilisi) Belirlenmesi

1.Adım

Çizelge 5.5'deki 23 adet 1.adım senaryosu Çizelge 5.4'deki 15 algortmada denenmiş; her bir senaryo için minimum hatayı veren algoritma ve hata değeri belirlenmiştir (Ek G). Buna göre minimum hatayı veren ilk 3 model (senaryo-algoritma ikilisi) Çizelge 5.22'de belirtilmiştir.

Çizelge 5.23 FHVRH işlem tipi için 1.adımda minimum hatayı veren ilk 3 model

Senaryo #	Alg. #	Geçmiş Gün Kuralı	Min. Hata
14	5	Geçmiş 1 ay önceki gün ve katları uzaklıktaki 5 adet veri ve her ilgili geçmiş günden 2 gün öncesi	0.0437
9	15	Geçmiş 20. gün ve katları uzaklıktaki 5 adet veri	0.0456
7	14	Geçmiş 5. gün ve katları uzaklıktaki 5 adet veri	0.0459

2. Adım

1. adım sonucu seçilen 14, 9 ve 7 numaralı senaryolardaki geçmiş gün kurallarının ikili ve üçlü kombinasyonları kullanılarak, 2. adım senaryoları oluşturulmuş ve Çizelge 5.4'deki 15 algoritma üzerinde denenmiştir. Elde edilen sonuçlar Çizelge 5.23'de verilmektedir.

Sonuçlara bakıldığında; 118 numaralı senaryo ve algoritma 5 ikilisinin 1. adımdaki senaryolara kıyasla en iyi 1. minimum hatayı verdiği görülmüştür.

3. Adım

1. adım ve 2. adım senaryolarından minimum hatayı veren en iyi ilk 4 senaryo (14, 118, 9, 7) seçilerek, her bir senaryoya Çizelge 5.6'daki 10 adet zaman farkı seçeneği uygulanmıştır.

Çizelge 5.24'de senaryo sütunundaki numaralar; temel senaryo sütunundaki numaralı senaryoya Çizelge 5.6'daki 10 adet zaman farkı seçeneğinin uygulanmasıyla elde edilen yeni senaryo numaralarını göstermektedir.

Üretilmiş olan bu 40 zaman farklı senaryodan en başarılı ilk 3 tanesinin sonuçları Çizelge 5.25'de yer almaktadır. Buna göre, 3. adımdaki senaryoların da 1. adımdaki senaryolara göre daha iyi sonuç vermediği görülmüştür.

İlk üç adım sonucunda; FHVRH işlem tipini tahmin etmede minimum hatayı veren en iyi ilk üç senaryo-algoritma ikilileri Çizelge 5.26'da yer almaktadır.

Çizelge 5.24 FHVRH işlem tipi için 2.adım sonuçları

Senaryo #	118 (9+14)	120 (7+9)	119 (7+14)	121 (7+9+14)
Alg. 1	0.1247	0.1235	0.1247	0.1247
Alg. 2	0.0753	0.0757	0.0526	0.0864
Alg. 3	0.0628	0.0578	0.0628	0.0628
Alg. 4	0.0709	0.0705	0.0709	0.0709
Alg. 5	0.0437	0.0476	0.0479	0.0563
Alg. 6	0.0733	0.0681	0.0744	0.0734
Alg. 7	0.0708	0.0702	0.0708	0.0708
Alg. 8	0.0708	0.0764	0.0738	0.0715
Alg. 9	0.156	0.0997	0.1186	0.1571
Alg. 10	0.0832	0.0823	0.0933	0.0933
Alg. 11	0.0663	0.071	0.0725	0.0666
Alg. 12	0.1144	0.1192	0.1062	0.1133
Alg. 13	0.0656	0.087	0.0633	0.0591
Alg. 14	0.0592	0.0565	0.0603	0.0597
Alg. 15	0.0515	0.0468	0.0525	0.0531
Min. Hata	0.0437	0.0468	0.0479	0.0531

Çizelge 5.25 FHVRH işlem tipi için 3.adım senaryoları

Senaryo #	Temel Senaryo #
220-229	14
340-349	7
370-379	9
440-449	118 (9+14)

Çizelge 5.26 FHVRH işlem tipi için en başarılı ilk üç 3. adım sonuçları

Senaryo #	226	446	370
Alg. 1	0.175	0.175	0.1633
Alg. 2	0.0504	0.0817	0.0705
Alg. 3	0.0637	0.0637	0.0708
Alg. 4	0.0967	0.0967	0.1022
Alg. 5	0.0627	0.0709	0.0677
Alg. 6	0.0828	0.0834	0.086
Alg. 7	0.0687	0.0687	0.0708
Alg. 8	0.0931	0.0917	0.07
Alg. 9	0.1029	0.1479	0.0746
Alg. 10	0.1147	0.1147	0.0993
Alg. 11	0.0941	0.091	0.0688
Alg. 12	0.1391	0.1127	0.136
Alg. 13	0.0816	0.0752	0.1123
Alg. 14	0.0959	0.1092	0.053
Alg. 15	0.059	0.051	0.0575
Min. Hata	0.0504	0.051	0.053

Çizelge 5.27 FHVRH işlem tipi için 3.adım sonunda en başarılı ilk üç sonuç

Senaryo #	Alg. #	Geçmiş Gün Kuralı	Min. Hata
14	5	Geçmiş 1 ay önceki gün ve katları uzaklıktaki 5 adet veri ve her ilgili geçmiş günden 2 gün öncesi	0.0437
118	5	Geçmiş 20. gün ve katları uzaklıktaki 5 adet veri + geçmiş 1 ay önceki gün ve katları uzaklıktaki 5 adet veri ve her ilgili geçmiş günden 2 gün öncesi	0.0437
9	15	Geçmiş 20. gün ve katları uzaklıktaki 5 adet veri	0.0456

4. Adım

En iyi sonucu veren senaryo14 – algoritma5 ikilisi için; ilgili REP Ağacı algoritmasının parametrelerinde değişiklik yapılarak, daha iyi sonuç elde edilmiştir. Bunun için; algoritmanın minimum sayı özelliği 1 olarak değiştirilmiş; böylece minimum hata 0.0437 değerinden 0.0424 değerine düşürülmüştür.

5. Adım

En iyi sonucu veren 14 numaralı senaryoya özellik azaltma algoritmaları uygulanarak, 5 numaralı algoritma üzerinde uygulanmış; ancak 4. adıma göre daha iyi bir sonuç elde edilememiştir.

Sonuç olarak; FHVRH işlem tipini tahmin etmede minimum hatayı veren en iyi model 14 numaralı senaryo (geçmiş 1 ay önceki gün ve katları uzaklıktaki 5 adet veri ve her ilgili geçmiş günden 2 gün öncesi) ile 5 numaralı algoritma (REP Ağacı) ikilisidir. REP Ağacı algoritmasının minimum sayı özelliği 1 olarak değiştirilmiştir. Minimum hata 0.0424 olarak alınmıştır.

5.2.7 GUMVR İşlem Tipi İçin Tahminde Kullanılacak Makine Öğrenmesi Modelinin (Senaryo-Algoritma İkilisi) Belirlenmesi

1.Adım

Çizelge 5.5'deki 23 adet 1.adım senaryosu Çizelge 5.4'deki 15 algortmada denenmiş; her bir senaryo için minimum hatayı veren algoritma ve hata değeri belirlenmiştir (Ek H). Buna göre minimum hatayı veren ilk 3 model (senaryo-algoritma ikilisi) Çizelge 5.27'de belirtilmiştir.

Çizelge 5.28 GUMVR işlem tipi için 1.adımda minimum hatayı veren ilk 3 model

Senaryo #	Alg. #	Geçmiş Gün Kuralı	Min. Hata
18	14	Geçmiş 1 ay önceki aynı iş günü ve katları uzaklıktaki 3 adet veri	0.063
17	5	Geçmiş 1 ay önceki aynı iş günü	0.065
20	5, 15	Ay sonuna uzaklığı aynı geçmiş 1 ay önceki veri	0.065

2. Adım

1. adım sonucu seçilen 18, 17 ve 20 numaralı senaryolardaki geçmiş gün kurallarının ikili ve üçlü kombinasyonları kullanılarak, 2. adım senaryoları oluşturulmuş ve Çizelge 5.4'deki 15 algoritma üzerinde denenmiştir. Elde edilen sonuçlar Çizelge 5.28'de verilmektedir (18 numaralı senaryo 17 numaralı senaryoyu içerdiği için, 17 ve 18'in bir arada olduğu kombinasyonlar dahil edilmemiştir). Sonuçlara bakıldığında; 114 numaralı senaryo ve algoritma 5 ikilisinin 1. adıma kıyasla en iyi 2. minimum hatayı verdiği görülmüştür.

Çizelge 5.29 GUMVR işlem tipi için 2.adım sonuçları

Senaryo #	114 (17+ 20)	113 (18+ 20)
Alg. 1	0.1821	0.1713
Alg. 2	0.0998	0.1059
Alg. 3	0.1434	0.1415
Alg. 4	0.1127	0.1121
Alg. 5	0.065	0.0678
Alg. 6	0.067	0.0677
Alg. 7	0.1021	0.1052
Alg. 8	0.0761	0.0739
Alg. 9	0.0911	0.1249
Alg. 10	0.1092	0.1109
Alg. 11	0.0768	0.0808
Alg. 12	0.0803	0.0863
Alg. 13	0.1767	0.1469
Alg. 14	0.0711	0.0683
Alg. 15	0.0651	0.0841
Min. Hata	0.065	0.0677

3. Adım

1. adım ve 2. adım senaryolarından minimum hatayı veren en iyi ilk 4 senaryo (18, 17, 20, 114) seçilerek, her bir senaryoya Çizelge 5.6'daki 10 adet zaman farkı uygulanmıştır.

Çizelge 5.29'da senaryo sütunundaki numaralar; temel senaryo sütunundaki numaralı senaryoya Çizelge 5.6'daki 10 adet zaman farkı seçeneğinin uygulanmasıyla elde edilen yeni senaryo numaralarını göstermektedir. Üretilmiş olan bu 40 zaman farklı senaryodan en başarılı ilk 3 tanesinin sonuçları ise Çizelge 5.30'da yer almaktadır.

4. Adım

En iyi sonucu veren senaryo18 – algoritma14 ikilisi için; ilgili Toplamsal Regresyon algoritmasının parametrelerinde değişiklik yapılarak, daha iyi sonuç elde edilmiştir. Bunun için, algoritmanın daralma özelliği 0.95 olarak değiştirilmiş; böylece minimum hata 0.063 değerinden 0.0608 değerine düşürülmüştür.

5. Adım

En iyi sonucu veren 18 numaralı senaryoya özellik azaltma algoritmaları uygulanarak, 14 numaralı algoritma üzerinde uygulanmış; ancak 4. adıma göre daha iyi bir sonuç elde edilememiştir.

Sonuç olarak; GUMVR işlem tipini tahmin etmede minimum hatayı veren en iyi model 18 numaralı senaryo (geçmiş 1 ay önceki aynı iş günü ve katları uzaklıktaki 3 adet veri) ile 14 numaralı algoritma (Toplamsal Regresyon) ikilisidir. Toplamsal Regresyon algoritmasının daralma özelliği 0.95, iterasyon sayısı 100 olarak değiştirilmiştir. Minimum hata 0.0608 olarak alınmıştır.

Çizelge 5.30 GUMVR işlem tipi için 3. adım senaryoları

Senaryo #	Temel Senaryo #
240-249	17
250-259	20
420-429	18
430-439	114 (17+20)

Çizelge 5.31 GUMVR işlem tipi için en başarılı ilk üç 3. adım sonuçları

Senaryo #	425	255	245
Alg. 1	0.0643	0.0696	0.0696
Alg. 2	0.0762	0.0661	0.0658
Alg. 3	0.065	0.0706	0.0706
Alg. 4	0.0655	0.0695	0.0661
Alg. 5	0.0649	0.0663	0.0697
Alg. 6	0.0716	0.0723	0.0712
Alg. 7	0.0648	0.0704	0.0704
Alg. 8	0.0733	0.0739	0.0716
Alg. 9	0.0841	0.0932	0.073
Alg. 10	0.0648	0.0704	0.0704
Alg. 11	0.0678	0.0744	0.0711
Alg. 12	0.0866	0.114	0.1111
Alg. 13	0.0986	0.0826	0.0889
Alg. 14	0.0838	0.0672	0.0744
Alg. 15	0.0642	0.0656	0.0679
Min. Hata	0.0642	0.0656	0.0658

Çizelge 5.32 GUMVR işlem tipi için 3.adım sonunda en başarılı ilk üç sonuç

Senaryo #	Alg. #	Geçmiş Gün Kuralı	Zaman Farkı Kuralı	Min. Hata
18	14	Geçmiş 1 ay önceki aynı iş günü ve katları uzaklıktaki 3 adet veri	-	0.063
425	15	Geçmiş 1 ay önceki aynı iş günü ve katları uzaklıktaki 3 adet veri	Veri kendisinden 20 gün önceki güne bölünerek ifade edilecek	0.0642
17	5	Geçmiş 1 ay önceki aynı iş günü	-	0.065
20	5,15	Ay sonuna uzaklığı aynı olan geçmiş 1 ay önceki güne ait veri	-	0.065

5.2.8 HABRM İşlem Tipi İçin Tahminde Kullanılacak Makine Öğrenmesi Modelinin (Senaryo-Algoritma İkilisi) Belirlenmesi

1.Adım

Çizelge 5.5'deki 23 adet 1.adım senaryosu Çizelge 5.4'deki 15 algoritmada denenmiş; her bir senaryo için minimum hatayı veren algoritma ve hata değeri belirlenmiştir (Ek I). Buna göre minimum hatayı veren ilk 3 model (senaryo-algoritma ikilisi) Çizelge 5.32'de belirtilmiştir.

Çizelge 5.33 HABRM işlem tipi için 1.adımda minimum hatayı veren ilk 3 model

Senaryo #	Alg. #	Geçmiş Gün Kuralı	Min. Hata
22	2	Ay sonuna uzaklığı aynı olan geçmiş 1 ay önceki gün ve katları uzaklıktaki 6 adet veri	0.0775
18	6	Geçmiş 1 ay önceki aynı iş günü ve katları uzaklıktaki 3 adet veri	0.0801
21	14	Ay sonuna uzaklığı aynı olan geçmiş 1 ay önceki gün ve katları uzaklıktaki 3 adet veri	0.0806

2.Adım

1. adım sonucu seçilen 22, 18 ve 21 numaralı senaryolardaki geçmiş gün kurallarının ikili kombinasyonları kullanılarak, 2. adım senaryoları oluşturulmuş ve Çizelge 5.4'deki 15 algoritma üzerinde denenmiştir. Elde edilen sonuçlar Çizelge 5.33'de verilmektedir (22 numaralı senaryo 21 numaralı senaryoyu içerdiği için, 21 ve 22'in bir arada olduğu kombinasyonlar dahil edilmemiştir).

Çizelge 5.34 HABRM işlem tipi için 2.adım sonuçları

Senaryo #	123 (18 + 21)	122 (18 + 22)
Alg. 1	0.1995	0.1928
Alg. 2	0.0896	0.0882
Alg. 3	0.1732	0.1889
Alg. 4	0.1684	0.1517
Alg. 5	0.1835	0.1679
Alg. 6	0.0923	0.1018
Alg. 7	0.1491	0.1391
Alg. 8	0.1157	0.0893
Alg. 9	0.323	0.186
Alg. 10	0.1569	0.1465
Alg. 11	0.1614	0.0966
Alg. 12	0.141	0.0969
Alg. 13	0.2282	0.2152
Alg. 14	0.0791	0.1584
Alg. 15	0.1051	0.1211
Min. Hata	0.0791	0.0882

Sonuçlara bakıldığında; 123 numaralı senaryo ve algoritma 14 ikilisinin 1. adımdaki senaryolara kıyasla en iyi 2. minimum hatayı verdiği görülmüştür.

3. Adım

1. adım ve 2. adım senaryolarından minimum hatayı veren en iyi ilk 4 senaryo (22, 123, 18, 21) seçilerek, her bir senaryoya Çizelge 5.6'daki 10 adet zaman farkı seçeneği uygulanmıştır.

Çizelge 5.34'de senaryo sütunundaki numaralar; temel senaryo sütunundaki numaralı senaryoya Çizelge 5.6'daki 10 adet zaman farkı seçeneğinin uygulanmasıyla elde edilen yeni senaryo numaralarını göstermektedir. Üretilmiş olan bu 40 zaman farklı senaryodan en başarılı ilk 3 tanesinin sonuçları Çizelge 5.35'de yer almaktadır.

Buna göre, 3. adımdaki senaryoların ilk iki adımdaki senaryolara göre daha iyi sonuç verdiği görülmüştür.

İlk üç adım sonucunda, HABRM işlem tipini tahmin etmede minimum hatayı veren en iyi ilk üç senaryo-algoritma ikilileri Çizelge 5.36'da yer almaktadır. Tablodan, geçmiş gün kuralı olarak "ay sonuna uzaklığı aynı olan geçmiş 1 ay önceki gün ve katları uzaklıktaki verilerin" kullanılmasının genel olarak iyi sonuç verdiği görülmüştür. Ayrıca; verinin kendisinden önceki bir güne bağlı olarak ifade edilmesi işleminde, bölme operatörünün daha iyi sonuç verdiği bulunmuştur.

Çizelge 5.35 HABRM işlem tipi için 3. adım senaryoları

Senaryo #	Temel Senaryo #
320-329	21
400-409	22
410-419	123 (18+21)
420-429	18

Çizelge 5.36 HABRM işlem tipi için en başarılı ilk üç 3. adım sonuçları

Senaryo #	404	325	415
Alg. 1	0.0915	0.0683	0.0683
Alg. 2	0.0739	0.0759	0.075
Alg. 3	0.0799	0.0976	0.0976
Alg. 4	0.0927	0.0718	0.0718
Alg. 5	0.0713	0.0693	0.0693
Alg. 6	0.0883	0.1316	0.1221
Alg. 7	0.0766	0.0659	0.0659
Alg. 8	0.0787	0.0703	0.0703
Alg. 9	0.3872	0.4418	0.3829
Alg. 10	0.0743	0.0656	0.0656
Alg. 11	0.064	0.0834	0.0722
Alg. 12	0.1629	0.1714	0.1905
Alg. 13	0.1365	0.1206	0.1107
Alg. 14	0.083	0.0834	0.1138
Alg. 15	0.0628	0.067	0.0673
Min. Hata	0.0628	0.0656	0.0656

Çizelge 5.37 HABRM işlem tipi için 3.adım sonunda en başarılı ilk üç sonuç

Senaryo #	Alg. #	Geçmiş Gün Kuralı	Zaman Farkı Kuralı	Min. Hata
404	15	Ay sonuna uzaklığı aynı olan geçmiş 1 ay önceki gün ve katları uzaklıktaki 6 adet veri	Veri kendisinden 5 gün önceki güne bölünerek ifade edilecek	0.0628
325	10	Ay sonuna uzaklığı aynı olan geçmiş 1 ay önceki gün ve katları uzaklıktaki 3 adet veri	Veri kendisinden 20 gün önceki güne bölünerek ifade edilecek	0.0656
415	10	Geçmiş 1 ay önceki aynı iş günü ve katları uzaklıktaki 3 adet veri + ay sonuna uzaklığı aynı olan geçmiş 1 ay önceki gün ve katları uzaklıktaki 3 adet veri	Veri kendisinden 20 gün önceki güne bölünerek ifade edilecek	0.0656

4. Adım

En iyi sonucu veren senaryo404 – algoritma15 ikilisi için; ilgili Torbalama algoritmasının parametrelerinde değişiklik yapılarak, daha iyi sonuç elde edilmiştir. Bunun için; algoritmanın iterasyon sayısı özelliği 100, REP Ağacı sınıflandırıcısının minimum sayı özelliği 1 olarak değiştirilmiştir. Böylece minimum hata 0.0628 değerinden 0.0601 değerine düşürülmüştür.

5. Adım

En iyi sonucu veren 404 numaralı senaryoya özellik azaltma algoritmaları uygulanarak, 15 numaralı algoritma üzerinde uygulanmış; ancak 4. adıma göre daha iyi bir sonuç elde edilememiştir.

Sonuç olarak; HABRM işlem tipini tahmin etmede minimum hatayı veren en iyi model 404 numaralı senaryo (geçmiş 1 ay önceki aynı iş günü ve katları uzaklıktaki 3 adet veri + veri kendisinden 5 gün önceki güne bölünerek ifade edilecek) ile 15 numaralı algoritma (Torbalama) ikilisidir. Torbalama algoritmasının iterasyon sayısı özelliği 100, REP Ağacı sınıflandırıcısının minimum sayı özelliği 1 olarak değiştirilmiştir. Minimum hata 0.0601 olarak alınmıştır.

5.2.9 HVALE İşlem Tipi İçin Tahminde Kullanılacak Makine Öğrenmesi Modelinin (Senaryo-Algoritma İkili) Belirlenmesi

1.Adım

Çizelge 5.5'deki 23 adet 1.adım senaryosu Çizelge 5.4'deki 15 algorithmada denenmiş; her bir senaryo için minimum hatayı veren algoritma ve hata değeri belirlenmiştir (Ek İ). Buna göre minimum hatayı veren ilk 3 model (senaryo-algoritma ikilisi) Çizelge 5.37'de belirtilmiştir.

Çizelge 5.38 HVALE işlem tipi için 1.adımda minimum hatayı veren ilk 3 model

Senaryo #	Alg. #	Geçmiş Gün Kuralı	Min. Hata
17	14	Geçmiş 1 ay önceki aynı iş günü	0.0295
1	14	Geçmiş 1 günlük veri	0.0304
12	13	Geçmiş 1 ay önceki gün ve katları uzaklıktaki 5 adet veri	0.0309

2. Adım

1. adım sonucu seçilen 17, 1 ve 12 numaralı senaryolardaki geçmiş gün kurallarının ikili ve üçlü kombinasyonları kullanılarak, 2. adım senaryoları oluşturulmuş ve Çizelge 5.4'deki 15 algoritma üzerinde denenmiştir. Elde edilen sonuçlar Çizelge 5.38'de verilmektedir.

Sonuçlara bakıldığında, 2.adımda oluşturulan senaryoların 1. adımdaki senaryolara göre daha iyi sonuç verdiği görülmüştür.

3. Adım

1. adım ve 2. adım senaryolarından minimum hatayı veren en iyi ilk 4 senaryo (102, 101, 17, 1) seçilerek, her bir senaryoya Çizelge 5.6'daki 10 adet zaman farkı seçeneği uygulanmıştır.

Çizelge 5.39'da senaryo sütunundaki numaralar; temel senaryo sütunundaki numaralı senaryoya Çizelge 5.6'daki 10 adet zaman farkı seçeneğinin uygulanmasıyla elde edilen yeni senaryo numaralarını göstermektedir.

Çizelge 5.39 HVALE işlem tipi için 2.adım sonuçları

Senaryo #	102 (12+ 17)	101 (1+12)	100 (1+17)	103 (1+12+ 17)
Alg. 1	0.0981	0.0981	0.0988	0.0981
Alg. 2	0.062	0.0684	0.0549	0.0567
Alg. 3	0.0672	0.0862	0.0771	0.0862
Alg. 4	0.0717	0.0717	0.0698	0.0717
Alg. 5	0.0422	0.0692	0.0435	0.0692
Alg. 6	0.0655	0.0645	0.0636	0.0639
Alg. 7	0.0719	0.0719	0.0694	0.0719
Alg. 8	0.0859	0.0873	0.0849	0.0852
Alg. 9	0.0655	0.0644	0.0464	0.0581
Alg. 10	0.0986	0.0986	0.0985	0.0986
Alg. 11	0.0883	0.0869	0.0888	0.086
Alg. 12	0.0851	0.075	0.0656	0.0841
Alg. 13	0.0281	0.0288	0.1026	0.0317
Alg. 14	0.04	0.0457	0.031	0.0406
Alg. 15	0.0569	0.0613	0.044	0.0612
Min. Hata	0.0281	0.0288	0.031	0.0317

Çizelge 5.40 HVALE işlem tipi için 2.adım sonuçları

Senaryo #	Temel Senaryo #
240-249	17
270-279	1
380-389	102 (12+17)
390-399	101(1+12)

Üretilmiş olan bu 40 zaman farklı senaryodan en başarılı ilk 3 tanesinin sonuçları Çizelge 5.40’da yer almaktadır. Buna göre, 3. adımdaki senaryoların 2. adımdaki senaryolara göre daha iyi sonuç vermediği görülmüştür.

Çizelge 5.41 HVALE işlem tipi için en başarılı ilk üç 3. adım sonuçları

Senaryo #	273	278	248
Alg. 1	0.1193	0.1303	0.1274
Alg. 2	0.0636	0.0459	0.0484
Alg. 3	0.0521	0.0525	0.0538
Alg. 4	0.0642	0.0532	0.0562
Alg. 5	0.0472	0.0512	0.05
Alg. 6	0.0629	0.0627	0.0711
Alg. 7	0.0603	0.0525	0.0527
Alg. 8	0.0796	0.0681	0.0982
Alg. 9	0.0485	0.101	0.0786
Alg. 10	0.0805	0.0989	0.0959
Alg. 11	0.0812	0.0754	0.1074
Alg. 12	0.063	0.062	0.0826
Alg. 13	0.0686	0.0671	0.0935
Alg. 14	0.0351	0.0447	0.0521
Alg. 15	0.0467	0.0388	0.0391
Min. Hata	0.0351	0.0388	0.0391

İlk 3 adım sonunda; HVALE işlem tipini tahmin etmede minimum hatayı veren en iyi üç senaryo-algoritma ikilisi Çizelge 5.41’de yer almaktadır.

Çizelge 5.42 HVALE işlem tipi için 3.adım sonunda en başarılı ilk üç sonuç

Senaryo #	Alg. #	Geçmiş Gün Kuralı	Min. Hata
102	13	Geçmiş 1 ay önceki gün ve katları uzaklıktaki 5 adet veri + geçmiş 1 ay önceki aynı iş günü	0.0281
101	13	Geçmiş 1 günlük veri + geçmiş 1 ay önceki gün ve katları uzaklıktaki 5 adet veri	0.0288
17	14	Geçmiş 1 ay önceki aynı iş günü	0.0295

4. Adım

En iyi sonucu veren senaryo102 – algoritma13 ikilisi için; ilgili “Kstar” algoritmasının parametrelerinde değişiklik yapılarak, daha iyi sonuç elde edilmeye çalışılmış; ancak başarılı olunamamıştır.

5. Adım

En iyi sonucu veren 102 numaralı senaryoya özellik azaltma algoritmaları uygulanarak, 13 numaralı algoritma üzerinde uygulanmış; ancak diğer adımlara göre daha iyi bir sonuç elde edilememiştir.

Sonuç olarak; HVALE işlem tipini tahmin etmede minimum hatayı veren en iyi model 102 numaralı senaryo (geçmiş 1 ay önceki gün ve katları uzaklıktaki 5 adet veri + geçmiş 1 ay önceki aynı iş günü) ile 13 numaralı algoritma (Kstar) ikilisidir. Minimum hata 0.0281 olarak alınmıştır.

5.2.10 MAASO İşlem Tipi İçin Tahminde Kullanılacak Makine Öğrenmesi Modelinin (Senaryo-Algoritma İkilisi) Belirlenmesi

1.Adım

Çizelge 5.5’deki 23 adet 1.adım senaryosu Çizelge 5.4’deki 15 algortmada denenmiş; her bir senaryo için minimum hatayı veren algoritma ve hata değeri belirlenmiştir (Ek J). Buna göre minimum hatayı veren ilk 3 model (senaryo-algoritma ikilisi) Çizelge 5.42’de belirtilmiştir.

Çizelge 5.43 MAASO işlem tipi için 1.adımda minimum hatayı veren ilk 3 model

Senaryo #	Alg. #	Geçmiş Gün Kuralı	Min. Hata
17	15	Geçmiş 1 ay önceki aynı iş günü	0.0352
1	15	Geçmiş 1 günlük veri	0.0359
9	15	Geçmiş 20. gün ve katları uzaklıktaki 5 adet veri	0.0376

2.Adım

1. adım sonucu seçilen 17, 1 ve 9 numaralı senaryolardaki geçmiş gün kurallarının ikili ve üçlü kombinasyonları kullanılarak, 2. adım senaryoları oluşturulmuş ve Çizelge 5.4'deki 15 algoritma üzerinde denenmiştir. Elde edilen sonuçlar Çizelge 5.43'de verilmektedir.

Sonuçlara bakıldığında; 100 numaralı senaryo ve algoritma 15 ikilisinin 1. adımdaki senaryolara kıyasla en iyi 3. minimum hatayı verdiği görülmüştür.

3. Adım

1. adım ve 2. adım senaryolarından minimum hatayı veren en iyi ilk 4 senaryo (17, 1, 100, 9) seçilerek, her bir senaryoya Çizelge 5.6'daki 10 adet zaman farkı seçeneği uygulanmıştır.

Çizelge 5.44'de senaryo sütunundaki numaralar; temel senaryo sütunundaki numaralı senaryoya Çizelge 5.6'daki 10 adet zaman farkı seçeneğinin uygulanmasıyla elde edilen yeni senaryo numaralarını göstermektedir.

Üretilmiş olan bu 40 zaman farklı senaryodan en başarılı ilk 3 tanesinin sonuçları Çizelge 5.45'de yer almaktadır.

Çizelge 5.44 MAASO işlem tipi için 2.adım sonuçları

Senaryo #	100 (1+17)	124 (1+9)	115 (9+17)	125 (1+9+17)
Alg. 1	0.138	0.1439	0.1439	0.1439
Alg. 2	0.0686	0.1051	0.09	0.0687
Alg. 3	0.0837	0.081	0.081	0.081
Alg. 4	0.109	0.1156	0.1156	0.1156
Alg. 5	0.0453	0.0553	0.0555	0.0555
Alg. 6	0.1008	0.1015	0.0985	0.0974
Alg. 7	0.1074	0.1125	0.1125	0.1125
Alg. 8	0.0971	0.1066	0.1164	0.1039
Alg. 9	0.0828	0.1257	0.0872	0.0959
Alg. 10	0.1144	0.1157	0.1244	0.1157
Alg. 11	0.0998	0.1209	0.1138	0.1069
Alg. 12	0.085	0.1899	0.0856	0.0837
Alg. 13	0.11	0.1101	0.11	0.1122
Alg. 14	0.0431	0.0458	0.0519	0.0474
Alg. 15	0.0367	0.039	0.0393	0.0405
Min. Hata	0.0367	0.039	0.0393	0.0405

Çizelge 5.45 MAASO işlem tipi için 3. adım senaryoları

Senaryo #	Temel Senaryo #
240-249	17
270-279	1
360-369	100 (1+17)
370-379	9

Çizelge 5.46 MAASO işlem tipi için en başarılı ilk üç 3. adım sonuçları

Senaryo #	242	365	245
Alg. 1	0.0951	0.0621	0.0621
Alg. 2	0.0562	0.0602	0.0607
Alg. 3	0.0766	0.0536	0.0536
Alg. 4	0.0891	0.0621	0.0621
Alg. 5	0.0425	0.0461	0.0475
Alg. 6	0.0907	0.0577	0.0583
Alg. 7	0.0794	0.0622	0.0622
Alg. 8	0.0881	0.057	0.0584
Alg. 9	0.0875	0.0594	0.0583
Alg. 10	0.0881	0.0623	0.0623
Alg. 11	0.089	0.0581	0.0599
Alg. 12	0.1325	0.0871	0.0864
Alg. 13	0.073	0.0634	0.0584
Alg. 14	0.0316	0.0358	0.037
Alg. 15	0.0382	0.0444	0.0405
Min. Hata	0.0316	0.0358	0.037

Buna göre, 3. adımdaki senaryoların ilk iki adımdaki senaryolara göre daha iyi sonuç verdiği görülmüştür.

İlk üç adım sonucunda; MAASO işlem tipini tahmin etmede minimum hatayı veren en iyi üç senaryo-algoritma ikilisi Çizelge 5.46'da yer almaktadır. Çizelgeye bakıldığında; ortak geçmiş gün kuralları olarak bir önceki gün ve bir ay önceki aynı iş günü verilebilir.

Çizelge 5.47 MAASO işlem tipi için 3.adım sonunda en başarılı ilk üç sonuç

Senaryo #	Alg. #	Geçmiş Gün Kuralı	Zaman Farkı Kuralı	Min. Hata
242	14	Geçmiş 1 ay önceki aynı iş günü	Veri kendisinden 20 gün önceki günden çıkarılarak ifade edilecek	0.0316
365	14	Geçmiş 1 günlük veri + geçmiş 1 ay önceki aynı iş günü	Veri kendisinden 20 gün önceki güne bölünerek ifade edilecek	0.0358
1	15	Geçmiş 1 günlük veri	-	0.0359

4. Adım

En iyi sonucu veren senaryo242 – algoritma14 ikilisi için; ilgili Toplamsal Regresyon algoritmasının parametrelerinde değişiklik yapılarak, daha iyi sonuç elde edilmiştir. Bunun için; algoritmanın iterasyon sayısı özelliği 300 olarak değiştirilmiştir. Böylece minimum hata 0.0316 değerinden 0.0275 değerine düşürülmüştür.

5. Adım

En iyi sonucu veren 242 numaralı senaryoya özellik azaltma algoritmaları uygulanarak, 14 numaralı algoritma üzerinde uygulanmış; ancak 4. adıma göre daha iyi bir sonuç elde edilememiştir.

Sonuç olarak; MAASO işlem tipini tahmin etmede minimum hatayı veren en iyi model 242 numaralı senaryo (geçmiş 1 ay önceki aynı iş günü + veri kendisinden 20 gün önceki günden çıkarılarak ifade edilecek) ile 14 numaralı algoritma (Toplamsal Regresyon) ikilisidir. Toplamsal Regresyon algoritmasının iterasyon sayısı özelliği 300 olarak değiştirilmiştir. Minimum hata 0.0275 olarak alınmıştır.

5.2.11 REZVM İşlem Tipi İçin Tahminde Kullanılacak Makine Öğrenmesi Modelinin (Senaryo-Algoritma İkilisi) Belirlenmesi

1.Adım

Çizelge 5.5'deki 23 adet 1.adım senaryosu Çizelge 5.4'deki 15 algortmada denenmiş; her bir senaryo için minimum hatayı veren algoritma ve hata değeri belirlenmiştir (Ek

K). Buna göre minimum hatayı veren ilk 3 model (senaryo-algoritma ikilisi) Çizelge 5.47’de belirtilmiştir.

Çizelge 5.48 REZVM işlem tipi için 1.adımda minimum hatayı veren ilk 3 model

Senaryo #	Alg. #	Geçmiş Gün Kuralı	Min. Hata
2	9	Geçmiş 5 günlük veri	0.0225
17	9	Geçmiş 1 ay önceki aynı iş günü	0.0239
7	9	Geçmiş 5. gün ve katları uzaklıktaki 5 adet veri	0.0242

2. Adım

1. adım sonucu seçilen 2, 17 ve 7 numaralı senaryolardaki geçmiş gün kurallarının ikili ve üçlü kombinasyonları kullanılarak, 2. adım senaryoları oluşturulmuş ve Çizelge 5.4’deki 15 algoritma üzerinde denenmiştir. Elde edilen sonuçlar Çizelge 5.48’de verilmektedir.

Sonuçlara bakıldığında; 130 numaralı senaryo ve algoritma 8 ikilisinin 1. adımdaki senaryolara kıyasla en iyi 3. minimum hatayı verdiği görülmüştür.

3. Adım

1. adım ve 2. adım senaryolarından minimum hatayı veren en iyi ilk 4 senaryo (2, 17, 7, 130) seçilerek, her bir senaryoya Çizelge 5.6’daki 10 adet zaman farkı seçeneği uygulanmıştır.

Çizelge 5.49’da senaryo sütunundaki numaralar; temel senaryo sütunundaki numaralı senaryoya Çizelge 5.6’daki 10 adet zaman farkı seçeneğinin uygulanmasıyla elde edilen yeni senaryo numaralarını göstermektedir.

Üretilmiş olan bu 40 zaman farklı senaryodan en başarılı ilk 3 tanesinin sonuçları Çizelge 5.50’de yer almaktadır.

Çizelge 5.49 REZVM işlem tipi için 2.adım sonuçları

Senaryo #	130 (2+7+17)	127 (2+17)	128 (2+7)	129 (7+17)
Alg. 1	0.0886	0.0902	0.0886	0.0886
Alg. 2	0.0254	0.0253	0.0259	0.0316
Alg. 3	0.0299	0.0293	0.0299	0.0623
Alg. 4	0.0617	0.0627	0.0581	0.0548
Alg. 5	0.0282	0.0323	0.0282	0.0342
Alg. 6	0.0363	0.0333	0.0357	0.0354
Alg. 7	0.0302	0.0302	0.0302	0.0423
Alg. 8	0.0242	0.0244	0.0249	0.0252
Alg. 9	0.0331	0.0525	0.0275	0.0349
Alg. 10	0.0311	0.031	0.0311	0.0419
Alg. 11	0.0254	0.0251	0.0257	0.0261
Alg. 12	0.0421	0.038	0.0406	0.0402
Alg. 13	0.0349	0.0407	0.0337	0.0352
Alg. 14	0.0363	0.027	0.036	0.0355
Alg. 15	0.0294	0.0288	0.029	0.0368
Min. Hata	0.0242	0.0244	0.0249	0.0252

Çizelge 5.50 REZVM işlem tipi için 3. adım senaryoları

Senaryo #	Temel Senaryo #
240-249	17
330-339	2
340-349	7
350-359	130 (2+7+17)

Çizelge 5.51 REZVM işlem tipi için en başarılı ilk üç 3. adım sonuçları

Senaryo #	333	353	344
Alg. 1	0.028	0.0286	0.0394
Alg. 2	0.0233	0.0257	0.0311
Alg. 3	0.0266	0.0273	0.036
Alg. 4	0.0282	0.032	0.0286
Alg. 5	0.0267	0.0249	0.0288
Alg. 6	0.0237	0.0248	0.0304
Alg. 7	0.0256	0.0267	0.0302
Alg. 8	0.0261	0.0263	0.0238
Alg. 9	0.0271	0.0673	0.0354
Alg. 10	0.0259	0.0265	0.0383
Alg. 11	0.0275	0.0264	0.0239
Alg. 12	0.036	0.0355	0.0415
Alg. 13	0.037	0.0359	0.0436
Alg. 14	0.0228	0.0252	0.0313
Alg. 15	0.0216	0.0222	0.028
Min. Hata	0.0216	0.0222	0.0238

Buna göre, 3. adımdaki senaryoların ilk iki adımdaki senaryolara göre daha iyi sonuç verdiği görülmüştür.

İlk üç adım sonucunda; REZVM işlem tipini tahmin etmede minimum hatayı veren en iyi üç senaryo-algoritma ikilileri Çizelge 5.51’de yer almaktadır. Çizelgeden 15 numaralı algoritmanın ilk üç senaryo için de en iyi sonucu veren algoritma olduğu görülmektedir. Ayrıca, tüm ikililer için ortak geçmiş gün kuralı olarak “geçmiş 5 günlük veri” kuralı söz konusudur.

Çizelge 5.52 REZVM işlem tipi için 3.adım sonunda en başarılı ilk üç sonuç

Senaryo #	Alg. #	Geçmiş Gün Kuralı	Zaman Farkı Kuralı	Min. Hata
333	15	Geçmiş 5 günlük veri	Veri kendisinden 1 gün önceki güne bölünerek ifade edilecek	0.0216
353	15	Geçmiş 5 günlük veri + geçmiş 5. gün ve katları uzaklıktaki 5 adet veri + geçmiş 1 ay önceki aynı iş günü	Veri kendisinden 1 gün önceki güne bölünerek ifade edilecek	0.0222
2	9	Geçmiş 5 günlük veri	-	0.0225

4.Adım

En iyi sonucu veren senaryo333 – algoritma15 ikilisi için; ilgili “Torbalama” algoritmasının parametrelerinde değişiklik yapılarak, daha iyi sonuç elde edilmiştir. Bunun için; algoritmanın iterasyon sayısı özelliği 300, REP Ağacı sınıflandırıcısının budama yok özelliği true olarak değiştirilmiştir. Böylece minimum hata 0.0216 değerinden 0.0211 değerine düşürülmüştür.

5. Adım

En iyi sonucu veren 333 numaralı senaryoya özellik azaltma algoritmaları uygulanarak, 15 numaralı algoritma üzerinde uygulanmış; ancak 4. adıma göre daha iyi bir sonuç elde edilememiştir.

Sonuç olarak; REZVM işlem tipini tahmin etmede minimum hatayı veren en iyi model 333 numaralı senaryo (geçmiş 5 günlük veri + veri kendisinden 1 gün önceki güne bölünerek ifade edilecek) ile 15 numaralı algoritma (Torbalama) ikilisidir. Torbalama algoritmasının iterasyon sayısı özelliği 300, REP Ağacı sınıflandırıcısının budama yok özelliği true olarak değiştirilmiştir. Minimum hata 0.0211 olarak alınmıştır.

5.2.12 SSKTA İşlem Tipi İçin Tahminde Kullanılacak Makine Öğrenmesi Modelinin (Senaryo-Algoritma İkili) Belirlenmesi

1.Adım

Çizelge 5.5'deki 23 adet 1.adım senaryosu Çizelge 5.4'deki 15 algorithmada denenmiş; her bir senaryo için minimum hatayı veren algoritma ve hata değeri belirlenmiştir (Ek L). Buna göre minimum hatayı veren ilk 3 model (senaryo-algoritma ikilisi) Çizelge 5.52'de belirtilmiştir.

Çizelge 5.53 SSKTA işlem tipi için 1.adımda minimum hatayı veren ilk 3 model

Senaryo #	Alg. #	Geçmiş Gün Kuralı	Min. Hata
6	13	Geçmiş 60 günlük veri	0.0078
8	5	Geçmiş 5. gün ve katları uzaklıktaki 5 adet veri ve her ilgili geçmiş günden 1 gün öncesi	0.0101
21	2	Ay sonuna uzaklığı aynı olan geçmiş 1 ay önceki gün ve katları uzaklıktaki 3 adet veri	0.0106

2. Adım

1. adım sonucu seçilen 6, 8 ve 21 numaralı senaryolardaki geçmiş gün kurallarının ikili kombinasyonları kullanılarak, 2. adım senaryoları oluşturulmuş ve Çizelge 5.4'deki 15 algoritma üzerinde denenmiştir. Elde edilen sonuçlar Çizelge 5.53'de verilmektedir.

Sonuçlara bakıldığında; 2.adımdaki senaryoların 1. adımdaki senaryolara kıyasla en iyi 2. ve 3. minimum hatayı verdiği görülmüştür.

3. Adım

1. adım ve 2. adım senaryolarından minimum hatayı veren en iyi ilk 4 senaryo (6, 133, 131, 8) seçilerek, her bir senaryoya Çizelge 5.6'daki 10 adet zaman farkı seçeneği uygulanmıştır.

Çizelge 5.54'de senaryo sütunundaki numaralar; temel senaryo sütunundaki numaralı senaryoya Çizelge 5.6'daki 10 adet zaman farkı seçeneğinin uygulanmasıyla elde edilen yeni senaryo numaralarını göstermektedir.

Çizelge 5.54 SSKTA işlem tipi için 2.adım sonuçları

Senaryo #	133 (6+8)	131 (6+21)	134 (6+8+21)	132 (8+21)
Alg. 1	0.1553	0.1549	0.1549	0.1549
Alg. 2	0.0421	0.1932	0.1932	0.0711
Alg. 3	0.1135	0.1033	0.1033	0.0699
Alg. 4	0.0499	0.055	0.055	0.0487
Alg. 5	0.0365	0.0872	0.0872	0.0398
Alg. 6	0.1027	0.1054	0.1101	0.0774
Alg. 7	0.0671	0.0605	0.0605	0.0605
Alg. 8	0.092	0.0654	0.0654	0.0726
Alg. 9	0.0486	0.0256	0.0314	0.0993
Alg. 10	0.0623	0.1619	0.1619	0.0748
Alg. 11	0.0989	0.0695	0.0689	0.1223
Alg. 12	0.0409	0.015	0.019	0.0241
Alg. 13	0.008	0.0086	0.011	0.0502
Alg. 14	0.0781	0.0527	0.0527	0.0888
Alg. 15	0.0665	0.0613	0.0613	0.0461
Min. Hata	0.008	0.0086	0.011	0.0241

Çizelge 5.55 SSKTA işlem tipi için 3. adım senaryoları

Senaryo #	Temel Senaryo #
210-219	6
300-309	131 (6+21)
310-319	8
510-519	133 (6+8)

Üretilmiş olan bu 40 zaman farklı senaryodan en başarılı ilk 3 tanesinin sonuçları Çizelge 5.55’de yer almaktadır. Buna göre, 3. adımdaki senaryoların ilk iki adımdaki senaryolara göre daha kötü sonuç verdiği görülmüştür.

Çizelge 5.56 SSKTA işlem tipi için en başarılı ilk üç 3. adım sonuçları

Senaryo #	218	308	309
Alg. 1	0.0042	0.0042	0.0043
Alg. 2	0.0042	0.0024	0.0043
Alg. 3	0.0042	0.0042	0.0043
Alg. 4	0.0019	0.0019	0.0016
Alg. 5	0.0039	0.0019	0.004
Alg. 6	0.0027	0.0027	0.0017
Alg. 7	0.0019	0.0019	0.0016
Alg. 8	0.0077	0.0073	0.01
Alg. 9	0.0018	0.0024	0.0016
Alg. 10	0.0021	0.002	0.002
Alg. 11	0.0018	0.0018	0.0014
Alg. 12	0.0032	0.0032	0.0019
Alg. 13	0.0013	0.0013	0.0014
Alg. 14	0.0015	0.0014	0.0462
Alg. 15	0.0013	0.0013	0.0014
Min. Hata	0.0013	0.0013	0.0014

İlk üç adım sonucunda, SSKTA işlem tipini tahmin etmede minimum hatayı veren en iyi ilk üç senaryo-algoritma ikilileri Çizelge 5.56’da yer almaktadır. Çizelgeden 13 numaralı algoritmanın ilk üç senaryo için de en iyi sonucu veren algoritma olduğu görülmektedir. Ayrıca, tüm ikililer için ortak geçmiş gün kuralı olarak “geçmiş 60 günlük veri” kuralı söz konusudur.

Çizelge 5.57 SSKTA işlem tipi için 3.adım sonunda en başarılı ilk üç sonuç

Senaryo #	Alg. #	Geçmiş Gün Kuralı	Min. Hata
6	13	Geçmiş 60 günlük veri	0.0078
133	13	Geçmiş 60 günlük veri + geçmiş 5. gün ve katları uzaklıktaki 5 adet veri ve her ilgili geçmiş günden 1 gün öncesi	0.008
131	13	Geçmiş 60 günlük veri + ay sonuna uzaklığı aynı olan geçmiş 1 ay önceki gün ve katları uzaklıktaki 3 adet veri	0.0086

4.Adım

En iyi sonucu veren senaryo6 – algoritma13 ikilisi için; ilgili KStar algoritmasının parametrelerinde değişiklik yapılarak, daha iyi sonuç elde edilmiştir. Bunun için; algoritmanın globalBlend özelliği 60 olarak değiştirilmiştir. Böylece minimum hata 0.0078 değerinden 0.0057 değerine düşürülmüştür.

5. Adım

En iyi sonucu veren 6 numaralı senaryoya özellik azaltma algoritmaları uygulanarak, 13 numaralı algoritma üzerinde uygulanmış; ancak 4. adıma göre daha iyi bir sonuç elde edilememiştir.

Sonuç olarak; SSKTA işlem tipini tahmin etmede minimum hatayı veren en iyi model 6 numaralı senaryo (geçmiş 60 günlük veri) ile 13 numaralı algoritma (Kstar) ikilisidir. Kstar algoritmasının globalBlend özelliği 60 olarak değiştirilmiştir. Minimum hata 0.0057 olarak alınmıştır.

5.2.13 VERGİ İşlem Tipi İçin Tahminde Kullanılacak Makine Öğrenmesi Modelinin (Senaryo-Algoritma İkilisi) Belirlenmesi

1.Adım

Çizelge 5.5'deki 23 adet 1.adım senaryosu Çizelge 5.4'deki 15 algortmada denenmiş; her bir senaryo için minimum hatayı veren algoritma ve hata değeri belirlenmiştir (Ek M). Buna göre minimum hatayı veren ilk 3 model (senaryo-algoritma ikilisi) Çizelge 5.57'de belirtilmiştir.

Çizelge 5.58 VERGI işlem tipi için 1.adımda minimum hatayı veren ilk 3 model

Senaryo #	Alg. #	Geçmiş Gün Kuralı	Min. Hata
4	13	Geçmiş 20 günlük veri	0.0075
6	13	Geçmiş 60 günlük veri	0.0092
3	13	Geçmiş 10 günlük veri	0.0097

2. Adım

1. adım sonucu seçilen 4, 6 ve 3 numaralı senaryolardan 6 numaralı senaryo diğer iki senaryoyu da kapsadığı için 2. adım senaryosu mevcut değildir.

3. Adım

1. adım senaryolarından minimum hatayı veren en iyi ilk 4 senaryo (4, 6, 3, 5) seçilerek, her bir senaryoya Çizelge 5.6'daki 10 adet zaman farkı seçeneği uygulanmıştır.

Çizelge 5.58'de senaryo sütunundaki numaralar; temel senaryo sütunundaki numaralı senaryoya Çizelge 5.6'daki 10 adet zaman farkı seçeneğinin uygulanmasıyla elde edilen yeni senaryo numaralarını göstermektedir. Üretilmiş olan bu 40 zaman farklı senaryodan en başarılı ilk 3 tanesinin sonuçları Çizelge 5.59'da yer almaktadır.

Buna göre, 3. adımdaki senaryoların ilk iki adımdaki senaryolara göre daha iyi sonuç verdiği görülmüştür.

İlk üç adım sonucunda; VERGI işlem tipini tahmin etmede minimum hatayı veren en iyi ilk üç senaryo-algoritma ikilileri Çizelge 5.60'da yer almaktadır. Tablodan 13 numaralı algoritmanın ilk üç senaryo için de en iyi sonucu veren algoritma olduğu görülmektedir.

Çizelge 5.59 VERGI işlem tipi için 3. adım senaryoları

Senaryo #	Temel Senaryo #
210-219	6
230-239	5
280-289	4
290-299	3

Çizelge 5.60 VERGI işlem tipi için en başarılı ilk üç 3. adım sonuçları

Senaryo #	230	280	299
Alg. 1	0.064	0.0631	0.0111
Alg. 2	0.0186	0.0401	0.0104
Alg. 3	0.0119	0.0118	0.0059
Alg. 4	0.042	0.0401	0.0053
Alg. 5	0.012	0.0124	0.0103
Alg. 6	0.0575	0.0549	0.0126
Alg. 7	0.0399	0.0392	0.0056
Alg. 8	0.0526	0.0517	0.008
Alg. 9	0.0292	0.07	0.0091
Alg. 10	0.0598	0.059	0.008
Alg. 11	0.0492	0.0502	0.0066
Alg. 12	0.0803	0.1838	0.0082
Alg. 13	0.0046	0.0046	0.0048
Alg. 14	0.033	0.0215	0.0105
Alg. 15	0.0089	0.0088	0.0067
Min. Hata	0.0046	0.0046	0.0048

Çizelge 5.61 VERGI işlem tipi için 3.adım sonunda en başarılı ilk üç sonuç

Senaryo #	Alg. #	Geçmiş Gün Kuralı	Zaman Farkı Kuralı	Min. Hata
230	13	Geçmiş 30 günlük veri	Veri kendisinden 1 gün önceki günden çıkarılarak ifade edilecek	0.0046
280	13	Geçmiş 20 günlük veri	Veri kendisinden 1 gün önceki günden çıkarılarak ifade edilecek	0.0046
299	13	Geçmiş 10 günlük veri	Veri kendisinden 3 ay önceki güne bölünerek ifade edilecek	0.0048

4.Adım

En iyi sonucu veren senaryo230 – algoritma13 ikilisi için; ilgili KStar algoritmasının parametrelerinde değişiklik yapılarak, daha iyi sonuç elde edilmiştir. Bunun için; algoritmanın globalBlend özelliği 60 olarak değiştirilmiştir. Böylece minimum hata 0.0046 değerinden 0.0039 değerine düşürülmüştür.

5. Adım

En iyi sonucu veren 230 numaralı senaryoya özellik azaltma algoritmaları uygulanarak, 13 numaralı algoritma üzerinde uygulanmış; ancak 4. adıma göre daha iyi bir sonuç elde edilememiştir.

Sonuç olarak; VERGI işlem tipini tahmin etmede minimum hatayı veren en iyi model 230 numaralı senaryo (geçmiş 30 günlük veri + veri kendisinden 1 gün önceki günden çıkarılarak ifade edilecek) ile 13 numaralı algoritma (Kstar) ikilisidir. Kstar algoritmasının globalBlend özelliği 60 olarak değiştirilmiştir. Minimum hata 0.0039 olarak alınmıştır.

5.2.14 VRMAN İşlem Tipi İçin Tahminde Kullanılacak Makine Öğrenmesi Modelinin (Senaryo-Algoritma İkilisi) Belirlenmesi

1.Adım

Çizelge 5.5'deki 23 adet 1.adım senaryosu Çizelge 5.4'deki 15 algortmada denenmiş; her bir senaryo için minimum hatayı veren algoritma ve hata değeri belirlenmiştir (Ek

N). Buna göre minimum hatayı veren ilk 3 model (senaryo-algoritma ikilisi) Çizelge 5.61’de belirtilmiştir.

Çizelge 5.62 VRMAN işlem tipi için 1.adımda minimum hatayı veren ilk 3 model

Senaryo #	Alg. #	Geçmiş Gün Kuralı	Min. Hata
6	13	Geçmiş 60 günlük veri	0.0266
14	2	Geçmiş 1 ay önceki gün ve katları uzaklıktaki 5 adet veri ve her ilgili geçmiş günden 2 gün öncesi	0.0409
5	5	Geçmiş 30 günlük veri	0.0413

2. Adım

1. adım sonucu seçilen 6, 14, 5 numaralı senaryolardaki geçmiş gün kurallarının ikili kombinasyonları kullanılarak, 2. adım senaryoları oluşturulmuş ve Çizelge 5.4’deki 15 algoritma üzerinde denenmiştir. Elde edilen sonuçlar Çizelge 5.62’de verilmektedir (6 numaralı senaryo 5 numaralı senaryoyu içerdiği için, 6 ve 5’in bir arada olduğu kombinasyonlar dahil edilmemiştir).

Sonuçlara bakıldığında; 104 numaralı senaryo ve algoritma 13 ikilisinin 1. adımdaki senaryolara kıyasla en iyi sonucu verdiği görülmüştür.

3. Adım

1. adım ve 2. adım senaryolarından minimum hatayı veren en iyi ilk 4 senaryo (104, 6, 14, 5) seçilerek, her bir senaryoya Çizelge 5.6’daki 10 adet zaman farkı seçeneği uygulanmıştır.

Çizelge 5.63’de senaryo sütunundaki numaralar; temel senaryo sütunundaki numaralı senaryoya Çizelge 5.6’daki 10 adet zaman farkı seçeneğinin uygulanmasıyla elde edilen yeni senaryo numaralarını göstermektedir.

Üretilmiş olan bu 40 zaman farklı senaryodan en başarılı ilk 3 tanesinin sonuçları Çizelge 5.64’de yer almaktadır.

Çizelge 5.63 VRMAN işlem tipi için 2.adım sonuçları

Senaryo #	104 (6+19)	105 (5+19)
Alg. 1	0.1325	0.1325
Alg. 2	0.1015	0.0458
Alg. 3	0.0728	0.0728
Alg. 4	0.115	0.115
Alg. 5	0.0609	0.0583
Alg. 6	0.1167	0.105
Alg. 7	0.1148	0.1148
Alg. 8	0.0775	0.0939
Alg. 9	0.0653	0.05
Alg. 10	0.1063	0.1162
Alg. 11	0.0978	0.0989
Alg. 12	0.045	0.1108
Alg. 13	0.0239	0.1142
Alg. 14	0.0544	0.056
Alg. 15	0.0632	0.0613
Min. Hata	0.0239	0.0458

Çizelge 5.64 VRMAN işlem tipi için 3. adım senaryoları

Senaryo #	Temel Senaryo #
200-209	104 (6+19)
210-219	6
220-229	14
230-239	5

Çizelge 5.65 VRMAN işlem tipi için en başarılı ilk üç 3. adım sonuçları

Senaryo #	204	214	234
Alg. 1	0.1469	0.1401	0.138
Alg. 2	0.0582	0.0766	0.0778
Alg. 3	0.095	0.0911	0.0835
Alg. 4	0.1253	0.1401	0.1194
Alg. 5	0.059	0.1119	0.0696
Alg. 6	0.1252	0.1114	0.0949
Alg. 7	0.0878	0.1122	0.1095
Alg. 8	0.0754	0.0677	0.0749
Alg. 9	0.1037	0.0846	0.0938
Alg. 10	0.0918	0.1158	0.1167
Alg. 11	0.0611	0.0709	0.0763
Alg. 12	0.0326	0.0445	0.1093
Alg. 13	0.0328	0.0357	0.0379
Alg. 14	0.0592	0.07	0.0608
Alg. 15	0.0667	0.0717	0.0676
Min. Hata	0.0326	0.0357	0.0379

Buna göre, 3. adımdaki senaryoların ilk iki adımdaki senaryolara göre daha iyi sonuç verdiği (en iyi 2. ve 3. minimum hata) görülmüştür.

İlk üç adım sonucunda; VRMAN işlem tipini tahmin etmede minimum hatayı veren en iyi ilk üç senaryo-algoritma ikilileri Çizelge 5.65’de yer almaktadır. Çizelgeden; tüm ikililer için geçmiş gün kuralı olarak “geçmiş 60 günlük veri” kuralının ortak olduğu görülmektedir.

Çizelge 5.66 VRMAN işlem tipi için 3.adım sonunda en başarılı ilk üç sonuç

Senaryo #	Alg. #	Geçmiş Gün Kuralı	Zaman Farkı Kuralı	Min. Hata
104	13	Geçmiş 60 günlük veri + geçmiş 1 ay önceki aynı iş günü ve katları uzaklıktaki 6 adet veri	-	0.0239
204	12	Geçmiş 60 günlük veri + geçmiş 1 ay önceki aynı iş günü ve katları uzaklıktaki 6 adet veri	Veri kendisinden 5 gün önceki güne bölünerek ifade edilecek	0.0326
214	13	Geçmiş 60 günlük veri	Veri kendisinden 5 gün önceki güne bölünerek ifade edilecek	0.0357

4. Adım

En iyi sonucu veren senaryo104 – algoritma13 ikilisi için; ilgili KStar algoritmasının parametrelerinde değişiklik yapılarak, daha iyi sonuç elde edilmiştir. Bunun için; algoritmanın globalBlend özelliği 10 olarak değiştirilmiştir. Böylece minimum hata 0.0239 değerinden 0.0238 değerine düşürülmüştür.

5. Adım

En iyi sonucu veren 104 numaralı senaryoya özellik azaltma algoritmaları uygulanarak, 13 numaralı algoritma üzerinde uygulanmış; ancak 4. adıma göre daha iyi bir sonuç elde edilememiştir.

Sonuç olarak; VRMAN işlem tipini tahmin etmede minimum hatayı veren en iyi model 104 numaralı senaryo (geçmiş 60 günlük veri + geçmiş 1 ay önceki aynı iş günü ve katları uzaklıktaki 6 adet veri) ile 13 numaralı algoritma (Kstar) ikilisidir. Kstar algoritmasının globalBlend özelliği 10 olarak değiştirilmiştir. Minimum hata 0.0238 olarak alınmıştır.

5.2.15 YDFON İşlem Tipi İçin Tahminde Kullanılacak Makine Öğrenmesi Modelinin (Senaryo-Algoritma İkili) Belirlenmesi

1.Adım

Çizelge 5.5'deki 23 adet 1.adım senaryosu Çizelge 5.4'deki 15 algoritmada denenmiş; her bir senaryo için minimum hatayı veren algoritma ve hata değeri belirlenmiştir (Ek O). Buna göre minimum hatayı veren ilk 3 model (senaryo-algoritma ikilisi) Çizelge 5.66'da belirtilmiştir.

Çizelge 5.67 YDFON işlem tipi için 1.adımda minimum hatayı veren ilk 3 model

Senaryo #	Alg. #	Geçmiş Gün Kuralı	Min. Hata
17	5	Geçmiş 1 ay önceki aynı iş günü	0.1659
20	5	Ay sonuna uzaklığı aynı olan geçmiş 1 ay önceki güne ait veri	0.1659
1	14	Geçmiş 1 günlük veri	0.1671

2.Adım

1. adım sonucu seçilen 17, 20 ve 1 numaralı senaryolardaki geçmiş gün kurallarının ikili ve üçlü kombinasyonları kullanılarak, 2. adım senaryoları oluşturulmuş ve Çizelge 5.4'deki 15 algoritma üzerinde denenmiştir. Elde edilen sonuçlar Çizelge 5.67'de verilmektedir.

Sonuçlara bakıldığında; 106 numaralı senaryonun 1. adımdaki senaryolara kıyasla aynı en iyi minimum hatayı verdiği görülmüştür.

3. Adım

1. adım ve 2. adım senaryolarından minimum hatayı veren en iyi ilk 4 senaryo (17, 20, 106, 1) seçilerek, her bir senaryoya Çizelge 5.6'daki 10 adet zaman farkı seçeneği uygulanmıştır.

Çizelge 5.68'de senaryo sütunundaki numaralar; temel senaryo sütunundaki numaralı senaryoya Çizelge 5.6'daki 10 adet zaman farkı seçeneğinin uygulanmasıyla elde edilen yeni senaryo numaralarını göstermektedir.

Çizelge 5.68 YDFON işlem tipi için 2.adım sonuçları

Senaryo #	106 (17+ 20)	100 (1+17)	107 (1+20)	108 (1+17+ 20)
Alg. 1	0.1755	0.1755	0.1755	0.1755
Alg. 2	0.2428	0.1829	0.1829	0.1836
Alg. 3	0.202	0.202	0.202	0.202
Alg. 4	0.1761	0.1761	0.1761	0.1761
Alg. 5	0.1659	0.1766	0.1934	0.1766
Alg. 6	0.2255	0.2072	0.2141	0.2146
Alg. 7	0.1747	0.1828	0.1828	0.1828
Alg. 8	0.1762	0.184	0.184	0.184
Alg. 9	0.4341	0.2824	0.292	0.408
Alg. 10	0.1875	0.185	0.185	0.185
Alg. 11	0.1751	0.1832	0.1812	0.1832
Alg. 12	0.3056	0.2428	0.2779	0.2801
Alg. 13	0.2271	0.2265	0.2584	0.2556
Alg. 14	0.1807	0.1776	0.1831	0.176
Alg. 15	0.1752	0.1809	0.178	0.1802
Min. Hata	0.1659	0.1755	0.1755	0.1755

Çizelge 5.69 YDFON işlem tipi için 3. adım senaryoları

Senaryo #	Temel Senaryo #
240-249	17
250-259	20
260-269	106 (17+20)
270-279	1

Üretilmiş olan bu 40 zaman farklı senaryodan en başarılı ilk 3 tanesinin sonuçları Çizelge 5.69’da yer almaktadır.

Çizelge 5.70 YDFON işlem tipi için en başarılı ilk üç 3. adım sonuçları

Senaryo #	249	259	269
Alg. 1	0.1375	0.1383	0.1375
Alg. 2	0.1208	0.1215	0.1219
Alg. 3	0.0954	0.0954	0.0954
Alg. 4	0.1486	0.1422	0.1486
Alg. 5	0.1324	0.1171	0.1324
Alg. 6	0.134	0.1294	0.1305
Alg. 7	0.1313	0.1313	0.1313
Alg. 8	0.1677	0.1646	0.1677
Alg. 9	0.1622	0.4417	0.2659
Alg. 10	0.1575	0.1575	0.1575
Alg. 11	0.1038	0.1013	0.1021
Alg. 12	0.1448	0.1573	0.1549
Alg. 13	0.1387	0.1091	0.1125
Alg. 14	0.1137	0.1013	0.1168
Alg. 15	0.1111	0.1083	0.1126
Min. Hata	0.0954	0.0954	0.0954

Buna göre, 3. adımdaki senaryoların ilk iki adımdaki senaryolara göre daha iyi sonuç verdiği görülmüştür.

İlk üç adımın sonucunda; YDFON işlem tipini tahmin etmede minimum hatayı veren en iyi üç senaryo-algoritma ikilileri Çizelge 5.70’de yer almaktadır. Tablodan 3 numaralı algoritmanın üç senaryo için de en iyi sonucu veren algoritma olduğu görülmektedir. Ayrıca; verinin kendisinden 3 ay önceki güne bölünerek ifade edildiği zaman farkı

seçeneği tüm senaryolar için geçerlidir. Geçmiş gün kuralı olarak ise, verinin hem “geçmiş bir ay önceki aynı iş günü” hem de “ay sonuna uzaklığı aynı olan geçmiş 1 ay önceki iş günü” kuralını kullanarak iyi modellenemediği görülmüştür.

Çizelge 5.71 YDFON işlem tipi için 3.adım sonunda en başarılı ilk üç sonuç

Senaryo #	Alg. #	Geçmiş Gün Kuralı	Zaman Farkı Kuralı	Min. Hata
249	3	Geçmiş 1 ay önceki aynı iş günü	Veri kendisinden 3 ay önceki güne bölünerek ifade edilecek	0.0954
259	3	Ay sonuna uzaklığı aynı olan geçmiş 1 ay önceki güne ait veri	Veri kendisinden 3 ay önceki güne bölünerek ifade edilecek	0.0954
269	3	Geçmiş 1 ay önceki aynı iş günü + Ay sonuna uzaklığı aynı olan geçmiş 1 ay önceki güne ait veri	Veri kendisinden 3 ay önceki güne bölünerek ifade edilecek	0.0954

4.Adım

En iyi sonucu veren senaryo249 – algoritma3 ikilisi için; ilgili Karar Tablosu algoritmasının parametrelerinde değişiklik yapılarak, daha iyi sonuç elde edilmeye çalışılmıştır. Ancak başarılı olunamamıştır.

5. Adım


En iyi sonucu veren 249 numaralı senaryoya özellik azaltma algoritmaları uygulanarak, 3 numaralı algoritma üzerinde uygulanmış; ancak diğer adımlara göre daha iyi bir sonuç elde edilememiştir.

Sonuç olarak; YDFON işlem tipini tahmin etmede minimum hatayı veren en iyi model 249 numaralı senaryo (geçmiş 1 ay önceki aynı iş günü + veri kendisinden 3 ay önceki güne bölünerek ifade edilecek) ile 3 numaralı algoritma (Karar Tablosu) ikilisidir. Minimum hata 0.0954 olarak alınmıştır.

5.2.16 İşlem Tiplerinin İlişkisinin İncelenmesi ve Bu Bilginin Tahmin İşleminde Kullanılması

Bir işlem tipinin başka bir işlem tipine etkisi olup olmadığını inceleyip, verileri tahmin etmede sadece kendi değerlerini değil etkileyen işlem tipine ait değerleri de bir özellik olarak kullanabiliriz. Bu fikirden yola çıkılarak; her bir işlem tipinin, diğer işlem tiplerine ait 1 gün önceki geçmiş veri ile korelasyonu incelenmiş ve ilgili işlem tipine hangi diğer işlem tiplerinin etkisinin olduğu bulunmuştur (korelasyon katsayısı olarak 0.5 değeri kullanılmıştır). Daha sonra bu işlem tipi için bundan önceki bölümde bulunmuş olan ve en iyi tahmini veren senaryoya, ilişkisi bulunan işlem tip(ler)ine ait 1 gün önceki geçmiş gün verisi özellik olarak eklenerek; daha iyi sonuç verip vermediği incelenmiştir.

Şekil 5.2’de; her bir işlem tipinin, diğer işlem tiplerine ait 1 gün önceki geçmiş veri ile korelasyonu çizdirilmiştir.




Şekil 5.2 Her bir işlem tipinin, diğer işlem tiplerine ait 1 gün önceki geçmiş veri ile korelasyonu

Buna göre, birbirini etkileyen işlem tipleri aşağıda sıralanmaktadır :

- REZVM (geçmiş 1 günlük verisi) → GUMVR
- GUMVR (geçmiş 1 günlük verisi) → REZVM
- FHVRH, FHEFT (geçmiş 1er günlük verileri) → VRMAN

5.2.16.1 REZVM İşlem Tipinin GUMVR İşlem Tipine Etkisinin İncelenmesi

GUMVR işlem tipine ait adetler ile REZVM işlem tipine ait (1 gün önceki) adetler, Şekil 5.3’de çizdirilmiştir. Benzerliğin grafikte daha rahat görülebilmesi için, küçük değerlere sahip olan GUMVR adetleri 7 ile çarpılmıştır.




Şekil 5.3 REZVM işlem tipinin GUMVR işlem tipine etkisi

GUMVR işlem tipi için en iyi sonucu veren 18 numaralı (geçmiş gün kuralı olarak, 1 ay önceki aynı iş günü ve katları uzaklıktaki 3 adet veriyi kullanan) senaryoya, REZVM işlem tipine ait 1 gün önceki geçmiş gün verisi özellik olarak eklenerek; 14 numaralı Toplamsal Regresyon algoritması üzerinde denenmiştir. Ancak, daha önceki adımlarda elde edilen en iyi minimum hata miktarı olan 0.0608 değerinden daha iyi bir sonuç elde edilememiştir.

5.2.16.2 GUMVR İşlem Tipinin REZVM İşlem Tipine Etkisinin İncelenmesi

REZVM işlem tipine ait adetler ile GUMVR işlem tipine ait (1 gün önceki) adetler, Şekil 5.4’de çizdirilmiştir. Benzerliğin grafikte daha rahat görülebilmesi için, küçük değerlere sahip olan GUMVR adetleri 7 ile çarpılmıştır.




Şekil 5.4 GUMVR işlem tipinin REZVM'ye etkisi

REZVM ödeme işlem tipi için en iyi sonucu veren 333 numaralı (geçmiş gün kuralı olarak, geçmiş 5 günlük veriyi kullanan; zaman farkı kuralı olarak ise 1 gün önceki güne bölmeyi kullanan) senaryoya, GUMVR işlem tipine ait 1 gün önceki geçmiş gün verisi özellik olarak eklenerek; 15 numaralı “Toralama” algoritması üzerinde denenmiştir. Torbalama algoritmasının iterasyon sayısı özelliğine 300, REP Ağacı sınıflandırıcısının budama yok özelliğine true değeri verilerek; 5. adımda elde edilmiş olan en iyi minimum hata miktarı 0.0211 değeri 0.0206 değerine düşürülmüştür.

5.2.16.3 FHVRH ile FHEFT İşlem Tiplerinin VRMAN İşlem Tipine Etkisinin İncelenmesi

VRMAN işlem tipine ait adetler ile FHVRH ve FHEFT işlem tiplerine ait (1 gün önceki) adetler, Şekil 5.5’de çizdirilmiştir. Benzerliğin grafikte daha rahat görülebilmesi için; FHVRH değerleri 12 ile, FHEFT değerleri 4 ile çarpılmıştır.



Şekil 5.5 FHVRH ve FHEFT işlem tiplerinin VRMAN'e etkisi

VRMAN ödeme işlem tipi için en iyi sonucu veren 104 numaralı (geçmiş gün kuralı olarak, geçmiş 60 günlük veri ile geçmiş 1 ay önceki aynı iş günü ve katları uzaklıktaki 6 adet veriyi kullanan) senaryoya, FHVRH ve FHEFT işlem tiplerine ait 1 gün önceki geçmiş gün verisi özellik olarak eklenerek; 13 numaralı KStar algoritması üzerinde denenmiştir. Ancak, 5. adımda elde edilmiş olan en iyi minimum hata miktarı olan 0.0238 değerinden daha iyi bir sonuç elde edilememiştir.

5.2.17 Makine Öğrenmesi Algoritmalarının Genel Değerlendirilmesi

- Çizelge 5.71’de, her bir işlem tipini modellemede makine öğrenmesi algoritmalarını kullanarak elde edilen en iyi sonuca ait bilgiler yer almaktadır.

Çizelge 5.72 Her bir işlem tipi için en iyi tahmini veren senaryo-makine öğrenmesi algoritması ikilileri

İşlem Tipi	Senaryo #	Alg. #	Geçmiş Gün Kuralı	Zaman Farkı Kuralı	Özellik Azaltma
EFTOD	1	14	Geçmiş 1 günlük veri	-	-
FAHES	339	10	Geçmiş 5 günlük veri	Veri kendisinden 3 ay önceki güne bölünerek ifade edilecek	CfsSubset Eval
FHEFT	17	14	Geçmiş 1 ay önceki aynı iş günü	-	-
FHVRH	14	5	Geçmiş 1 ay önceki gün ve katları uzaklıktaki 5 adet veri ve her ilgili geçmiş günden 2 gün öncesi	-	-
GUMVR	18	14	Geçmiş 1 ay önceki aynı iş günü ve katları uzaklıktaki 3 adet veri	-	-
HABRM	404	15	Ay sonuna uzaklığı aynı olan geçmiş 1 ay önceki gün ve katları uzaklıktaki 6 adet veri	Veri kendisinden 5 gün önceki güne bölünerek ifade edilecek	-
HVALE	102	13	Geçmiş 1 ay önceki gün ve katları uzaklıktaki 5 adet veri + geçmiş 1 ay önceki aynı iş günü	-	-

Çizelge 5.73 Her bir işlem tipi için en iyi tahmini veren senaryo-makine öğrenmesi algoritması ikilileri (devam)


İşlem Tipi	Senaryo #	Alg. #	Geçmiş Gün Kuralı	Zaman Farkı Kuralı	Özellik Azaltma
MAASO	242	14	Geçmiş 1 ay önceki aynı iş günü	Veri kendisinden 20 gün önceki günden çıkarılarak ifade edilecek	-
REZVM	333	15	Geçmiş 5 günlük veri	Veri kendisinden 1 gün önceki güne bölünerek ifade edilecek	-
SSKTA	6	13	Geçmiş 60 günlük veri	-	-
VERGI	230	13	Geçmiş 30 günlük veri	Veri kendisinden 1 gün önceki günden çıkarılarak ifade edilecek	-
VRMAN	104	13	Geçmiş 60 günlük veri + geçmiş 1 ay önceki aynı iş günü ve katları uzaklıktaki 6 adet veri	-	-
YDFON	249	3	Geçmiş 1 ay önceki aynı iş günü	Veri kendisinden 3 ay önceki güne bölünerek ifade edilecek	-

- Senaryoların genel performansını incelemek için; en az 5 işlem tipinde birden kullanılmış olan senaryoların her bir işlem tipinde kaçınıcı olduğu ve ortalaması hesaplanmıştır. Ek Ö'de bu bilgiler yer almaktadır (İşlem tiplerindeki parantez içindeki sayılar, o işlem tipi için toplam kaç tane senaryonun denendiğini ifade etmektedir).


Ek Ö incelendiğinde; Çizelge 5.71'e benzer olarak, yine her işlem tipi için farklı farklı senaryoların başarılı olduğu görülmekle birlikte, genel olarak 17 ve 20 numaralı senaryoların daha başarılı olduğu görülmüştür. Bu senaryoların bileşenlerine bakıldığında; 17 numaralı senaryo bir ay önceki aynı iş gününü, 20 numaralı senaryo ise ay sonuna uzaklığı aynı olan bir ay önceki iş gününü ifade etmekte ki buradan bu iki senaryonun da veriyi temelde birbirine çok benzer bir şekilde ifade ettiği sonucuna varılabilir. 2. ve 3. en iyi senaryolar incelendiğinde ise; "geçmiş 5 günlük veri" ve "geçmiş 1 günlük veri" senaryolarının başarılı olduğu görülmüştür. Bu da verinin genel

olarak kendisinden 1 gün öncesi ya da 1 hafta öncesi ile ilişkili olduğunu göstermektedir.

- Algoritmaların genel değerlendirmesi için, algoritmalar üç kategoriye bölünmüştür : regresyon, karar ağacı, örnek tabanlı. Bu kategorilerin her bir işlem tipinde ortalama kaçınıcı olduğu bilgisi Şekil 5.6'da gösterilmiştir. Şekil 5.7'de ise, her bir algoritmaya ait ortalama ve standart sapma bilgileri gösterilmektedir.



Şekil 5.6 Makine öğrenmesi algoritmalarının performansları



Şekil 5.7 Makine öğrenmesi algoritmalarının ortalama ve standart sapma bilgisi


Şekiller incelendiğinde; en başarılı ilk 4 algoritmanın (Torbalama, Toplamsal Regresyon, M5 Kuralları, REP Ağacı) genelde karar ağacı tabanlı algoritmalar olduğu görülmektedir. Bununla birlikte en başarılı ilk iki algoritma (Torbalama, Toplamsal Regresyon) topluluk tabanlı algoritmalar. Benzer bileşenlere sahip senaryoların benzer başarılar göstermesi durumu, algoritmalarda da görülmektedir. Ayrıca, algoritmaların standart sapmaları incelendiğinde; en küçük standart sapmaya sahip algoritmanın (Torbalama) aynı zamanda en başarılı algoritma olduğu ve bu nedenle en güvenilir algoritma olduğu anlaşılmıştır. Ayrıca; işlem tiplerinin farklı karakteristiklerine sahip olduğu bilgisi, Şekil 5.7'de de görülmektedir. Örnek olarak; Kstar algoritması için, en başarılı olduğu işlem

tiplerinin varlığına rağmen genel olarak başarı ortalamasının düşük olduğu görülmektedir.


- Her bir işlem tipi için genel modelleme başarısını belirlemede Çizelge 5.72 kullanılmıştır. Bu çizelgedeki “Zero Rule hata” sütunu, verinin tamamı tek bir değer (ortalama) ile tahmin edildiğinde elde edilen hatayı ifade etmektedir. Dolayısıyla bu Zero Rule hata değeri, veri modellemesinin başarımında referans noktası olarak düşünülebilir; sadece bu değerden daha düşük hataya sahip modeller başarılı olarak değerlendirilebilir. Bu değerlendirme için; en iyi başarıya sahip modelin hata miktarının (“min. hata” sütunu) “Zero Rule hata” sütunundaki değerden çıkarılmasıyla elde edilen “iyileşme miktarı” ve bu iyileşme miktarının yüzdesini ifade eden “iyileşme oranı” sütunları kullanılmaktadır.

Çizelge 5.74 Her bir işlem tipi için makine öğrenmesi algoritmalarının modelleme başarısı


İşlem Tipi	Min. Hata	Zero Rule Hata	İyileşme Miktarı	İyileşme Oranı (%)	Gerçek, Tahmin ve Bunların Arasındaki Fark (Hata) Grafiği
EFTOD	0.0317	0.098	0.0663	67.65306	Şekil 5.8
FAHES	0.0015	0.0051	0.0036	70.58824	Şekil 5.9
FHEFT	0.0308	0.1529	0.1221	79.85612	Şekil 5.10
FHVRH	0.0424	0.1247	0.0823	65.9984	Şekil 5.11
GUMVR	0.0608	0.1713	0.1105	64.50671	Şekil 5.12
HABRM	0.0601	0.0915	0.0314	34.31694	Şekil 5.13
HVALE	0.0281	0.0981	0.07	71.35576	Şekil 5.14
MAASO	0.0275	0.0951	0.0676	71.08307	Şekil 5.15
REZVM	0.0211	0.028	0.0069	24.64286	Şekil 5.16
SSKTA	0.0057	0.1553	0.1496	96.32968	Şekil 5.17
VERGI	0.0039	0.064	0.0601	93.90625	Şekil 5.18
VRMAN	0.0238	0.1325	0.1087	82.03774	Şekil 5.19
YDFON	0.0954	0.1375	0.0421	30.61818	Şekil 5.20




Şekil 5.8 EFTOD - gerçek değer, tahmin ve bunların arasındaki fark (hata)




Şekil 5.9 FAHES - gerçek değer, tahmin ve bunların arasındaki fark (hata)




Şekil 5.10 FHEFT - gerçek değer, tahmin ve bunların arasındaki fark (hata)




Şekil 5.11 FHVRH - gerçek değer, tahmin ve bunların arasındaki fark (hata)




Şekil 5.12 GUMVR - gerçek değer, tahmin ve bunların arasındaki fark (hata)




Şekil 5.13 HABRM - gerçek değer, tahmin ve bunların arasındaki fark (hata)




Şekil 5.14 HVALE - gerçek değer, tahmin
ve bunların arasındaki fark (hata)




Şekil 5.15 MAASO - gerçek değer, tahmin
ve bunların arasındaki fark (hata)




Şekil 5.16 REZVM - gerçek değer, tahmin
ve bunların arasındaki fark (hata)




Şekil 5.17 SSKTA - gerçek değer, tahmin
ve bunların arasındaki fark (hata)



Şekil 5.18 VERGI - gerçek değer, tahmin
ve bunların arasındaki fark (hata)



Şekil 5.19 VRMAN - gerçek değer, tahmin
ve bunların arasındaki fark (hata)



Şekil 5.20 YDFON - gerçek değer, tahmin ve bunların arasındaki fark (hata)

Zero Rule hata değerinin yüksek olması verinin zaman ekseninde çok değişken olduğunun bir göstergesidir. Örneğin; Zero Rule hata değeri en düşük (dolayısıyla zamanla değişimi çok az) olan FAHES verisinin modellenme türü, her günün kendisinden 3 ay önceki güne bölümüyle ifadesidir. Buna göre FAHES veri türünde elde edilen gerçek başarı; kullanılan algoritmadan kaynaklı değil, verinin zamanla değişmeyen bir modelinin bulunmuş olması sebebiyledir. Zamanla değişimi çok az olan bir veride algoritmaya iyileştirebileceği pek fazla bir şey kalmamış demektir.

Dolayısıyla düşük Zero Rule hata değerleri senaryo seçimindeki başarıyı, yüksek iyileşme miktarları ise algoritmaların başarımını göstermektedir. Buna göre senaryo seçimlerinin başarıyı incelendiğinde (en düşük Zero Rule hata değerine sahip), en iyi başarımın sırasıyla FAHES, REZMV ile VERGI olduğu; en kötü ise FHEFT, SSKTA ile GUMVR olduğu görülmektedir. Algoritmaların başarıyı incelendiğinde ise en çok iyileşme sağlanan (iyileşme oranı en yüksek olan) ilk üç işlem tipi sırasıyla SSKTA, VERGI ve VRMAN'dır. En kötüler ise YDFON, GUMVR'dir. YDFON incelendiğinde hem Zero Rule hata değerinin yüksek olduğu (model senaryo seçiminde başarılı olunamadığı), hem de iyileşme miktarının düşük olduğu (algoritmaların da başarılı olamadığı) görülmektedir. GUMVR'de ise, Zero Rule hata değerinin yüksek olmasına rağmen iyileşme miktarının yüksek olması algoritmaların iyi iş çıkardığını göstermektedir.

Ayrıca; çizelgeler incelendiğinde hatalı günler arasında belli bir korelasyon olmadığı görülmüştür. Eğer hatalı günler arasında bir korelasyon (örneğin 5 günde bir yükselen bir hata vb.) olsaydı; bu durum, verinin içerisinde hala modellenemeyen bir şablonun

varlığının göstergesi olacaktı. Dolayısıyla söylenebilir ki verilerin içerisinde modellenmemiş şablon kalmamıştır.

Sonuç olarak, en başarılı senaryo ve algoritmalar işlem tipine göre oldukça farklılık göstermektedir ki bu durum bu çalışma boyunca izlenen -çok çeşitli senaryo üretip deneme- yönteminin haklılığını ortaya koymaktadır. Ancak, bununla birlikte senaryo 17 (geçmiş gün parametresi : bir ay önceki aynı iş günü) ve senaryo 20 (geçmiş gün parametresi : ay sonuna uzaklığı aynı olan bir ay önceki iş günü) ile Torbalama ve Toplamsal Regresyon algoritmalarının daha başarılı olduğu söylenebilir.

5.3 Genel Değerlendirme

Bu çalışmada elde edilen tüm sonuçlar bir araya getirildiğinde; her bir işlem tipi için elde edilen en iyi model bilgisi Çizelge 5.73’de yer almaktadır.

Çizelge 5.75 Her bir işlem tipi için çalışma sonucunda elde edilen en iyi model bilgileri

İşlem Tipi	Algoritma	Varsayılan Harici Algoritma Parametreleri	Geçmiş Gün Kuralı	Zaman Farkı Kuralı	Özellik Azaltma	Min. Hata Miktarı
EFTOD	Toplamsal Regresyon	- sınıflandırıcı : torbalama - iterasyon sayısı : 100	Geçmiş 1 günlük veri	-	-	0.0317
FAHES	Basit Doğrusal Regresyon	-	Geçmiş 5 günlük veri	Veri kendisinden 3 ay önceki güne bölünerek ifade edilecek	CfsSubset Eval	0.0015
FHEFT	Toplamsal Regresyon	- sınıflandırıcı : torbalama - iterasyon sayısı : 100 - daralma : 0.99	Geçmiş 1 ay önceki aynı iş günü	-	-	0.0308
FHVRH	REP Ağacı	- minimum sayı : 1	Geçmiş 1 ay önceki gün ve katları uzaklıktaki 5 adet veri ve her ilgili geçmiş günden 2 gün öncesi	-	-	0.0424

Çizelge 5.76 Her bir işlem tipi için çalışma sonucunda elde edilen en iyi model bilgileri
(devam)

İşlem Tipi	Algoritma	Varsayılan Harici Algoritma Parametreleri	Geçmiş Gün Kuralı	Zaman Farkı Kuralı	Özellik Azaltma	Min. Hata Miktarı
GUMVR	Toplamsal Regresyon	- iterasyon sayısı : 100 - daralma : 0.95	Geçmiş 1 ay önceki aynı iş günü ve katları uzaklıktaki 3 adet veri	-	-	0.0608
HABRM	Torbalama	- iterasyon sayısı : 100 - REP Ağacı sınıflandırıcısının minimum sayı özelliği : 1	Ay sonuna uzaklığı aynı olan geçmiş 1 ay önceki gün ve katları uzaklıktaki 6 adet veri	Veri kendisinden 5 gün önceki güne bölünerek ifade edilecek	-	0.0601
HVALE	Kstar	-	Geçmiş 1 ay önceki gün ve katları uzaklıktaki 5 adet veri + geçmiş 1 ay önceki aynı iş günü	-	-	0.0281
MAASO	Toplamsal Regresyon	- iterasyon sayısı : 300	Geçmiş 1 ay önceki aynı iş günü	Veri kendisinden 20 gün önceki günden çıkarılarak ifade edilecek	-	0.0275
REZVM	Torbalama	- iterasyon sayısı : 300 - REP Ağacı sınıflandırıcısının budama yok özelliği : True	Geçmiş 5 günlük veri	Veri kendisinden 1 gün önceki güne bölünerek ifade edilecek	-	0.0211
SSKTA	Kstar	- globalBlend : 60	Geçmiş 60 günlük veri	-	-	0.0057
VERGI	Kstar	- globalBlend : 60	Geçmiş 30 günlük veri	Veri kendisinden 1 gün önceki günden çıkarılarak ifade edilecek	-	0.0039
VRMAN	Kstar	- globalBlend : 10	Geçmiş 60 günlük veri + geçmiş 1 ay önceki aynı iş günü ve katları uzaklıktaki 6 adet veri	-	-	0.0238

Çizelge 5.77 Her bir işlem tipi için çalışma sonucunda elde edilen en iyi model bilgileri
(devam)

İşlem Tipi	Algoritma	Varsayılan Harici Algoritma Parametreleri	Geçmiş Gün Kuralı	Zaman Farkı Kuralı	Özellik Azaltma	Min. Hata Miktarı
YDFON	2 Durumlu Markov Rejim Değişim Modeli	N/A	Geçmiş 30 günlük veri	N/A		0.0558

Çizelge 5.73 incelendiğinde, verilerin modellenmesinde en başarılı algoritmaların bir işlem türü hariç makine öğrenmesi algoritmaları olduğu görülmüştür. YDFON işlem tipinde ise Markov Rejim Değişim Modeli daha iyi sonuç vermiştir.

SONUÇ VE ÖNERİLER

Yıldızların hareketini tahmin etmekle başlayan öngörme çabası, 21. yüzyılda sosyal ve ekonomik hayattaki tüm parametreleri tahmin etme arayışı aşamasına ulaşmıştır. Geleceğin öngörülmesi, özellikle ekonomi ve finans alanında yaygın olarak ihtiyaç duyulan bir konudur. Zamanımızda bu alanlarda faaliyet gösteren birçok şirket için gelecekle ilgili öngörülerde bulunmak önemli bir gereksinim olmuştur. Yakın geleceğin geçmişten çok fazla farklı olmayacağı varsayılırsa, geçmiş veriden çıkarılmış olan kurallar gelecekte de geçerli olacak ve ilerisi için doğru tahmin yapılmasını sağlayacaktır.

Bu tez çalışmasında; büyük bir bankadan alınan 1.5 yıllık gerçek veri kullanılarak, bankanın operasyonel iş süreçleri analiz edilmiş ve bu süreçlere ait işlem sayılarının gelecekte nasıl gerçekleşeceği modellenmiştir. Bu modeller yardımıyla bankadaki yönetmenler yoğunluğu önceden fark edebilecek ve gerekli düzenlemeleri yaparak kaynakların etkin kullanımını ve işlemlerin hedef süreye uyumluluğunu sağlayabileceklerdir.

Bu çalışmada kullanılan algoritmalar temel olarak iki kategoride değerlendirilmiştir : klasik zaman serisi algoritmaları ve makine öğrenmesi algoritmaları. Klasik zaman serisi algoritmaları olarak Box-Jenkins (ARIMA) Modeli, Elman Ağ Modeli ile Markov Rejim Değişim Modeli kullanılmıştır. Makine öğrenmesi algoritmaları olarak ise M5 Kuralları, Karar Tablosu, Birleşik Kural, REP Ağacı, Gauss Süreçleri, Eş Aralıklı Regresyon, Doğrusal Regresyon, Yapay Sinir Ağı, Basit Doğrusal Regresyon, Karar Destek Vektörleriyle Regresyon, Ibk, Kstar, Toplamsal Regresyon ve Torbalama algoritmaları kullanılmıştır.

Ardından sonuçlar karşılaştırılarak en iyi tahmini gerçekleştiren sistem oluşturulmuştur. Çalışmada performans metriği olarak ise Ortalama Karesel Hatanın Kare Kökü kullanılmıştır. Çünkü verinin içeriği gereği hatanın oranı değil miktarı daha anlamlıdır. Ayrıca verinin %90'ı eğitim için, %10'u test için kullanılmıştır.

Makine öğrenmesi algoritmalarını kullanırken, giriş verisinin ifade edilmesinde üç temel öge kullanılmıştır : Birinci öge olan tahmin edilecek güne ait hangi (haftanın kaçınıcı günü, tatil tipi vb.) ek bilgilerin kullanılacağı ögesi; tahminlerde haftalık, aylık vb. şablonlardan faydalanabilmek için kullanılmıştır. İkinci öge, geçmiş hangi günlerin özellik olarak kullanılacağı bilgisidir. Bu ögenin alabileceği değerlere örnek olarak; “geçmiş X günlük veri”, “ay sonuna olan uzaklığı, tahmin edilecek günün ay sonuna olan uzaklığı ile aynı olan; geçmiş X adet gün” verilebilir. Son öge ise verinin geçmiş bir güne bağlı olarak ifade edilip edilmeyeceği bilgisidir. Bu öge seriyi dönemsel etkilerden arındırma için farkını ya da oranını alarak yapılmıştır. Örnek olarak; giriş verisi için, verinin kendisini değil de bir gün önceki değerinden farkını alarak kullanma verilebilir. Bu üç ögenin çeşitli kombinasyonları kullanılarak verinin farklı gösterim şekilleri (senaryolar) üretilmiştir. Ayrıca; senaryoların üretimi manuel yapılırsa çok zaman alacağından, bu işlem için .NET'te genel bir program yazılarak işlem otomatikleştirilmiştir. Böylece; senaryoların oluşturulması, yeni bir senaryo eklenmesi ya da mevcut senaryoda güncelleme yapılması çok kolaylaşmıştır.

Çalışma sonucunda verilerin modellenmesinde en başarılı algoritmaların bir işlem türü hariç diğer tüm işlem tipleri için makine öğrenmesi algoritmaları olduğu görülmüştür. YDFON işlem tipinde ise Markov Rejim Değişim Modeli daha iyi sonuç vermiştir. Diğer taraftan en başarılı makine öğrenmesi algoritmalarının işlem tipleri bazında dağılımı incelendiğinde çok fazla ortaklık olmadığı görülerek; verilerin birbirinden farklı karakteristiklere, ifade ediliş şekillerine sahip olduğu anlaşılmıştır ki bu durum bu çalışma boyunca izlenen -çok çeşitli senaryo üretip deneme- yönteminin haklılığını ortaya koymaktadır.

Senaryo seçimlerinin başarımı incelendiğinde, en iyi başarımın sırasıyla FAHES, REZMV ile VERGI olduğu; en kötü ise FHEFT, SSKTA ile GUMVR olduğu görülmektedir.

Algoritmaların başarımı incelendiğinde ise en çok iyileşme sağlanan ilk üç işlem tipi sırasıyla SSKTA, VERGI ve VRMAN'dır.

Makine öğrenmesi algoritmalarının genel performansı incelendiğinde; en başarılı ilk 4 algoritmanın (Toralama, Toplamsal Regresyon, M5 Kuralları, REP Ağacı) genelde karar ağacı tabanlı algoritmalar olduğu görülmektedir. Bununla birlikte en başarılı ilk iki algoritma (Toralama, Toplamsal Regresyon) topluluk tabanlı algoritmalarlardır. Ayrıca, algoritmaların standart sapmaları incelendiğinde; en küçük standart sapmaya sahip algoritmanın aynı zamanda en başarılı algoritma (Toralama) olduğu ve bu nedenle en güvenilir algoritma olduğu anlaşılmıştır.

Makine öğrenmesi metotlarında senaryoların genel performansı incelendiğinde; her işlem tipi için farklı senaryoların başarılı olduğu görülmekle birlikte, genel olarak 17 ve 20 numaralı senaryoların daha başarılı olduğu görülmüştür. Bu senaryoların bileşenlerine bakıldığında; 17 numaralı senaryo bir ay önceki aynı iş gününü, 20 numaralı senaryo ise ay sonuna uzaklığı aynı olan bir ay önceki iş gününü ifade etmekte ki buradan bu iki senaryonun da veriyi temelde birbirine çok benzer bir şekilde ifade ettiği sonucuna varılabilir. 2. ve 3. en iyi senaryolar incelendiğinde ise; "geçmiş 5 günlük veri" ve "geçmiş 1 günlük veri" senaryolarının başarılı olduğu görülmüştür. Bu da verinin genel olarak kendisinden 1 gün öncesi yada 1 hafta öncesi ile ilişkili olduğunu göstermiştir.

Ayrıca, bu çalışmada her bir işlem tipinin, diğer işlem tiplerine ait 1 gün önceki geçmiş veri ile korelasyonu incelenmiş ve ilgili işlem tipine hangi diğer işlem tiplerinin etkisinin olduğu bulunmuştur (korelasyon katsayısı olarak 0.5 değeri kullanılmıştır). Bu bilgi kullanılarak; REZVM ödeme işlem tipi için GUMVR işlem tipine ait 1 gün önceki geçmiş gün verisi de ek özellik olarak kullanıldığında daha iyi sonuç elde edildiği görülmüştür.

Yapılan bu çalışma ile; yönetmenlerin operasyonel süreçlere ait gelecekteki işlem sayılarını tahmin eden bir sisteme sahip olmaları mümkün olmuştur. Bu sayede yoğunluğu önceden fark edecek olan yönetmenler gerekli düzenlemeleri yoğunluk öncesinde yapabilecekler ve yaşanan yoğunluğun azaltılması mümkün olabilecektir. Böylece, kaynakların etkin kullanımı ve işlemlerin hedeflenen sürede gerçekleştirilmesi sağlanacaktır.

Çalışmada geliştirilen sistemin elde ettiği performansın daha da yükseltilebilmesi için daha fazla veri kullanılması gerekmektedir. Kullanılan 1.5 yıllık veri ile yıllık desenlerin yakalanabilmesi mümkün olmamıştır, ayrıca daha fazla veri ile daha fazla aylık şablonun ortaya çıkarılması sağlanabilir. Ayrıca çalışmada her bir işlem tipinin hangi diğer işlem tiplerine etkisi olduğunun bulunması için sadece 1 gün önceki geçmiş veri kullanılmıştır. Bu geçmiş gün verisi geriye doğru daha da genişletilerek, daha fazla ilişkinin ortaya çıkartılması ve böylece daha iyi tahmin elde edilmesi mümkün olabilir.

KAYNAKLAR

- [1] Kaynar, O. ve Tastan, S., (2009). "Zaman Serisi Analizinde MLP Yapay Sinir Ağları ve ARIMA Modelinin Karşılaştırılması", Erciyes Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi, 33:161-172.
- [2] Box, G.P. ve Jenkins, G.M., (1970). Time Series Analysis: Forecasting and Control, Holden-Day Inc., San Francisco.
- [3] Hamzaçebi, C. ve Kutay, F., (2004). "Yapay Sinir Ağları ile Türkiye Elektrik Enerjisi Tüketiminin 2010 Yılına Kadar Tahmini", Gazi Üniv. Müh. Mim. Fak. Der., 19(3):227-233.
- [4] Çuhadar, M., Güngör, I. ve Göksu, A., (2009). "Turizm Talebinin Yapay Sinir Ağları İle Tahmini ve Zaman Serisi Yöntemleri İle Karşılaştırma Analizi", Süleyman Demirel Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi, 14(1):99-114.
- [5] Kaynar, O., Tastan, S. ve Demirkoparan, F., (2010). "Ham Petrol Fiyatlarının Yapay Sinir Ağları İle Tahmini", Ege Akademik Bakış, 10(2):561-575.
- [6] Gobenez, Y., (2008). "Growth Rate Prediction Using ANN in Production Management", Selçuk Üniversitesi Sosyal Bilimler Enstitüsü Dergisi, 18:555-567.
- [7] Akgül, I., Koç, S. ve Koç, S. , (2007). "Cari İşlemler Dengesi Rejim Değişim Modelleri İle Modellenebilir mi?", 8. Türkiye Ekonometri ve İstatistik Kongresi, Malatya.
- [8] Bildirici, M., ve Bozoklu, U., (2007). "Bireysel Beklentiler ve Çoklu Ekonomik Denge : Markov Geçiş Modeli", 8. Türkiye Ekonometri ve İstatistik Kongresi, 24-25 Mayıs 2007, Malatya.
- [9] Mohammadi, K., Eslami, H.R. ve Dardashti, S.D., (2005). "Comparison of Regression, ARIMA and ANN Models for Reservoir Inflow Forecasting using Snowmelt Equivalent (a Senaryo study of Karaj)", J. Agric. Sci. Technol., 7:17-30.
- [10] Lahane, A.G., (2008). Financial Forecasting: Comparison Of ARIMA, FFNN and SVR, Master Tezi, Department Of Computer Science And Engineering Indian Institute of Technology, Bombay.

- [11] Azo, E.M., (1994). Neural Network Time Series Forecasting of Financial Markets, John Wiley & Sons, New York.
- [12] Kumar, M. ve Thenmozhi, M., (2004). "Forecasting nifty index futures returns using neural network and arima models", Financial Engineering and Applications, 437.
- [13] Neeraj, M., Pankaj, J., Kumar, L.A. Ve Goutam, D., (2005). "Artificial Neural Network Models for Forecasting Stock Price Index in Bombay Stock Exchange", IIMA Working Papers, 1 Ekim 2005, Ahmedabad.
- [14] Chen, W., Shih, J. ve and Wu, S., (2006). "Comparison of Support-Vector Machines and Back Propagation Neural Networks in Forecasting The Six Major Asian Stock Markets", International Journal of Electronic Finance, 1(1):49-67.
- [15] Trafalis, T. Ve Ince, H., (2000). "Support Vector Machine for Regression and Applications to Financial Forecasting", IJCNN, 06:6348.
- [16] Cao, L. ve Tay, F.E.H., (2001). "Financial Forecasting Using Support Vector Machines", Neural Computing & Applications, 10(2):184-192.
- [17] Wijaya, Y.B., Kom, S., Napitupulu, T.A., (2010). "Stock Price Prediction: Comparison of Arima and Artificial Neural Network Methods - An Indonesia Stock's Senaryo", Advances in Computing, Control and Telecommunication Technologies (ACT).
- [18] Xie, W., Yu, L., Xu, S. ve Wang, S., (2006). "A New Method for Crude Oil Price Forecasting Based on Support Vector Machines", ICCS 2006, Part IV, LNCS 3994.
- [19] Chatfield, C. (1989). The analysis of time series: an introduction, Chapman and Hall Ltd., London.
- [20] Sevüktekin, M. ve Nargeleçekenler, M., (2010). Ekonometrik Zaman Serileri Analizi, Nobel Yayınevi, Ankara.
- [21] Serper, Ö. (2000). Uygulamalı İstatistik, Ezgi Kitabevi, Bursa.
- [22] Yılmaz, A. (2004). Hava kirliliği zaman serilerinin öngörü amacıyla analizinde ARIMA modelleri ve bir uygulama, Yüksek Lisans Tezi, Anadolu Üniversitesi, Sosyal Bilimler Enstitüsü, Eskişehir.
- [23] Atlas, M. (2000). Statistlik II: Çözümlü Örnekler, Birlik Ofset Yayıncılık, Eskişehir.
- [24] Naylor, T.H., Seaks, T.G. ve Wichern, D.W., (1972). "Box-Jenkins Methods: An Alternative To Econometric Models", International Statistical Review, 40(2).
- [25] Elman, J.L., (1990). "Finding structure in time", Cognitive Science, 14(2):179-211.
- [26] Geri Dönüşümlü Ağlar,
<http://members.comu.edu.tr/boraugurlu/courses/bm434/week8/hafta8.pdf>,
10 Ocak 2011.

- [27] Zucchini, W. ve MacDonald, I.L., (2009). Hidden Markov Models for Time Series: An Introduction Using R, Chapman and Hall, New York.
- [28] MS_Regress - The MATLAB Package for Markov Regime Switching Models, <http://ssrn.com/abstract=1714016>, 10 Ocak 2011.
- [29] Weka : Data Mining Software in Java, <http://www.cs.waikato.ac.nz/ml/weka/>, 10 Ocak 2011.
- [30] Quinlan, J.R., (1992). "Learning with continuous classes", 5th Australian Joint Conference on Artificial Intelligence, Singapore.
- [31] Data mining model trees, <http://datamining.ihe.nl/research/model-trees.htm>, 10 Ocak 2011.
- [32] Kohavi, R., (1995). "The Power of Decision Tables", 8th European Conference on Machine Learning, 174-189.
- [33] Breiman L., Friedman, J., Olshen, R. ve Stone, C., (1984). Classification and Regression Trees, Chapman and Hall, New York.
- [34] Alpaydin, E., Introduction to Machine Learning, <http://www.cmpe.boun.edu.tr/~ethem/i2ml/slides/v1-1/i2ml-chap9-v1-1.ppt>, 10 Ocak 2011.
- [35] Mackay, D.J.C., (1998). Introduction to Gaussian Processes. Dept. of Physics Cambridge University, UK.
- [36] Best, M.J., ve Chakravarti, N., (1990). "Active Set Algorithms For Isotonic Regression; A Unifying Framework", Mathematical Programming, 47: 425-439.
- [37] Akaike, H., (1974). "A New Look At The Statistical Model Identification", IEEE Transactions on Automatic Control, 19(6):716-723.
- [38] Lippmann, R.P., (1987). "An Introduction to Computing with Neural Nets", IEEE ASSP Magazine.
- [39] Vapnik, V. Ve Cortes, C., (1995). "Support-Vector Networks", Machine Learning, 20.
- [40] Shevade, S.K., Keerthi, S.S. ve Bhattacharyya, C., (1999). "Improvements to the SMO Algorithm for SVM Regression", IEEE Transactions on Neural Networks.
- [41] Smola, A.J., ve Schoelkopf, B., (1998). A tutorial on support vector regression.
- [42] Cover, T.T. ve Hart, P.E., (1967). "Nearst Neighbour Pattern Classification", IEEE Transactions on Information Theory 11, 21-27.
- [43] Hart, P.E., (1968). "The Condensed Nearst Neighbour Rule", IEEE Transactions on Information Theory, 14:515-516.
- [44] Gates, G.W., (1972). "The Reduced Nearst Neighbour Rule", IEEE Transactions on Information Theory, 18:431-433.
- [45] Aha, D. ve Kibler, D., (1991). "Instance-Based Learning Algorithms", Machine Learning, 6:37-66.

- [46] Cleary, G. ve Trigg, L.E., (1995). "K*: An Instance-Based Learner Using an Entropic Distance Measure", 12th International Conference on Machine Learning, 108-114.
- [47] Gradient Boosting, <http://www-stat.stanford.edu/~jhf/ftp/stobst.ps>, 10 Ocak 2011.
- [48] Freund, Y. ve Schapire, R.E., (1997). "A Decision-Theoretic Generalization Of On-Line Learning and An Application To Boosting", Journal of Computer and System Sciences, 55.
- [49] Breiman, L., (1996). "Bagging predictors", Machine Learning, 24(2).

EKONOMETRİK MODELLER (AR, MA, ARIMA) KULLANILARAK ELDE EDİLEN SONUÇLAR

Algoritma	EFTOD	FAHES	FHEFT	FHVRH	GUMVR	HABRM	HVALE	MAASO	REZVM	SSKTA	VERGI	VRMAN	YDFON
AR(1,0)	0.104	0.0827	0.1542	0.1353	0.1075	0.1537	0.1002	0.1304	0.0303	0.202	0.0992	0.1293	0.1818
AR(5,0)	0.0965	0.0843	0.0923	0.1052	0.0807	0.1177	0.0769	0.1277	0.0286	0.2019	0.1	0.1257	0.1843
AR(10,0)	0.0835	0.085	0.0725	0.092	0.0835	0.0937	0.0667	0.1257	0.0278	0.1986	0.1031	0.1126	0.1813
AR(20,0)	0.0684	0.0863	0.0589	0.0746	0.0813	0.0857	0.058	0.1043	0.0272	0.1428	0.1051	0.0961	0.1873
AR(30,0)	0.0651	0.0839	0.054	0.0733	0.0823	0.0856	0.0562	0.0934	0.0256	0.128	0.1018	0.0879	0.1961
AR(1,1)	0.1316	0.0925	0.2066	0.1783	0.0946	0.1263	0.1278	0.1479	0.0286	0.2425	0.1173	0.1599	0.1889
AR(5,1)	0.1055	0.0935	0.0907	0.1058	0.082	0.1006	0.0769	0.1444	0.0291	0.2218	0.1084	0.13	0.1916
AR(10,1)	0.0792	0.0915	0.072	0.0912	0.0842	0.0890	0.0669	0.1372	0.0286	0.2164	0.1097	0.1164	0.1881

AR(20,1)	0.0701	0.0983	0.0579	0.0694	0.0818	0.0832	0.0582	0.1057	0.0275	0.1791	0.1132	0.1	0.1932
AR(30,1)	0.0665	0.0906	0.0552	0.073	0.0818	0.0803	0.0556	0.0986	0.0258	0.133	0.1056	0.0916	0.2001
MA(1,0)	0.1009	0.0838	0.1537	0.1353	0.1447	0.1773	0.1001	0.1317	0.0636	0.2023	0.0991	0.1269	0.1838
AR(5,0)	0.0949	0.0853	0.1123	0.113	0.1081	0.1381	0.0819	0.1292	0.0387	0.2017	0.1012	0.1199	0.1756
MA(10,0)	0.0885	0.0844	0.099	0.1096	0.1031	0.1353	0.0783	0.12	0.0331	0.1896	0.1013	0.1206	0.1925
MA(20,0)	0.0804	0.081	0.0812	0.0947	0.093	0.1166	0.0727	0.1105	0.0311	0.1777	0.0994	0.1105	0.1955
MA(30,0)	0.0744	0.0829	0.0748	0.0975	0.093	0.1025	0.0665	0.1052	0.03	0.1531	0.0993	0.1107	0.1971
MA(1,1)	0.1085	0.0961	0.1543	0.1364	0.0797	0.1299	0.0998	0.1484	0.029	0.2028	0.1105	0.1364	0.1788
MA(5,1)	0.0977	0.0939	0.1258	0.1281	0.0823	0.0966	0.0901	0.1317	0.0287	0.2037	0.1066	0.1297	0.1862
MA(10,1)	0.0916	0.0922	0.1046	0.1121	0.0852	0.0959	0.0783	0.1271	0.0277	0.1964	0.1085	0.1214	0.1851
MA(20,1)	0.0805	0.104	0.0872	0.1079	0.0823	0.0977	0.0765	0.1199	0.0281	0.1864	0.1182	0.1176	0.1947
MA(30,1)	0.0748	0.0954	0.0744	0.0981	0.0864	0.0958	0.0683	0.1107	0.0264	0.1594	0.1137	0.1143	0.1983
ARIMA(1,1,0)	0.0996	0.0826	0.1493	0.1365	0.0792	0.1538	0.095	0.1289	0.0284	0.2022	0.0993	0.1237	0.1747
ARIMA(1,5,0)	0.0948	0.0814	0.1123	0.1124	0.0813	0.1334	0.0819	0.129	0.0285	0.1903	0.0935	0.1202	0.1858
ARIMA(5,5,0)	0.0808	0.0847	0.0668	0.0791	0.077	0.1214	0.061	0.1268	0.0285	0.186	0.0993	0.1016	0.1811
ARIMA(1,10,0)	0.0886	0.0821	0.0992	0.1115	0.0848	0.1079	0.0781	0.1205	0.0272	0.1896	0.097	0.1207	0.1893
ARIMA(5,10,0)	0.0802	0.085	0.0638	0.0783	0.0744	0.1018	0.0602	0.1145	0.028	0.1906	0.0969	0.0999	0.1857

ARIMA(10,10,0)	0.064	0.0842	0.0579	0.0799	0.0754	0.0819	0.0537	0.1077	0.0289	0.1646	0.1044	0.0943	0.2074
ARIMA(1,20,0)	0.0797	0.0809	0.0808	0.0974	0.0822	0.0998	0.0738	0.11	0.0311	0.1799	0.099	0.1116	0.1967
ARIMA(5,20,0)	0.0697	0.0812	0.0599	0.0745	0.0843	0.0888	0.0566	0.106	0.0275	0.1633	0.1119	0.1151	0.1918
ARIMA(10,20,0)	0.0633	0.1021	0.0547	0.0633	0.0841	0.0808	0.0539	0.1116	0.0309	0.1619	0.1095	0.0935	0.1945
ARIMA(20,20,0)	0.063	0.1015	0.0424	0.0744	0.0881	0.0831	0.1297	0.4382	0.0306	0.1558	0.0926	0.0797	0.2774
ARIMA(1,30,0)	0.0744	0.0885	0.0707	0.0997	0.0857	0.1024	0.0658	0.108	0.0299	0.1531	0.1046	0.1106	0.1968
ARIMA(5,30,0)	0.0706	0.0945	0.0557	0.0783	0.0803	0.0971	0.0559	0.1002	0.0297	0.1533	0.1003	0.1068	0.1987
ARIMA(10,30,0)	0.0624	0.0877	0.0469	0.0784	0.0853	0.0985	0.0506	0.0972	0.0292	0.1767	0.1197	0.0974	0.2017
ARIMA20,30,0)	0.0633	0.0825	0.0515	0.1923	0.1105	0.0994	0.0559	0.114	0.0308	0.1533	0.1109	0.0811	0.2935
ARIMA(30,30,0)	0.0626	0.0938	0.0494	0.1814	0.098	0.2360	0.06	0.1435	0.0316	0.614	0.0997	0.0733	0.2525
ARIMA(1,1,1)	0.1056	0.0916	0.154	0.1364	0.0798	0.1047	0.0997	0.1323	0.029	0.2035	0.1066	0.1322	0.1811
ARIMA(1,5,1)	0.097	0.0938	0.1198	0.1224	0.0838	0.0965	0.0854	0.1316	0.0284	0.2037	0.1021	0.1267	0.1863
ARIMA(5,5,1)	0.0761	0.0917	0.0678	0.0786	0.0729	0.0781	0.0602	0.1306	0.0302	0.1816	0.1104	0.104	0.1826
ARIMA(1,10,1)	0.0901	0.0926	0.1035	0.1098	0.0848	0.0966	0.0777	0.126	0.0277	0.1961	0.1066	0.1213	0.1848
ARIMA(5,10,1)	0.0812	0.0963	0.0658	0.0772	0.0752	0.0810	0.0597	0.1244	0.0283	0.1828	0.1152	0.1007	0.1857
ARIMA(10,10,1)	0.0647	0.0917	0.0589	0.0679	0.0745	0.0766	0.0544	0.115	0.0264	0.1579	0.1106	0.0975	0.2047
ARIMA(1,20,1)	0.0815	0.1006	0.09	0.1022	0.0824	0.0976	0.076	0.1185	0.0275	0.1806	0.1051	0.1171	0.1912

ARIMA(5,20,1)	0.0798	0.1051	0.0601	0.0747	0.087	0.0820	0.0569	0.1202	0.0274	0.1791	0.1179	0.1107	0.1917
ARIMA(10,20,1)	0.064	0.095	0.0586	0.0706	0.0768	0.0799	0.054	0.1059	0.0282	0.181	0.1111	0.0919	0.2238
ARIMA(20,20,1)	0.0618	0.0924	0.0528	0.0745	0.0802	0.0838	0.0554	0.0942	0.026	0.1285	0.1097	0.0898	0.2089
ARIMA(1,30,1)	0.0785	0.0977	0.0737	0.1009	0.0859	0.0965	0.0683	0.1116	0.0265	0.1586	0.1148	0.1139	0.1976
ARIMA(5,30,1)	0.0702	0.0972	0.0893	0.0837	0.08	0.0919	0.0652	0.1067	0.0264	0.1597	0.1127	0.1005	0.2016
ARIMA(10,30,1)	0.0635	0.0967	0.0574	0.0802	0.0869	0.0828	0.0544	0.1176	0.0293	0.1637	0.1176	0.0863	0.2521
ARIMA(20,30,1)	0.0614	0.093	0.0534	0.0733	0.0926	0.0778	0.0531	0.0953	0.0283	0.1625	0.1201	0.089	0.1993
ARIMA(30,30,1)	0.0666	0.0869	0.0571	0.3983	0.0856	0.0920	0.0567	0.0883	0.0252	0.1719	0.1016	0.078	0.2249

ELMAN AĞ KULLANILARAK ELDE EDİLEN SONUÇLAR

Geçmiş Gün	SKN#	EFTOD	FAHES	FHEFT	FHVRH	GUMVR	HABRM	HVALE	MAASO	REZVM	SSKTA	VERGI	VRMAN	YDFON
1	5	0.2336	0.0392	0.1397	0.1847	0.0876	0.1326	0.1022	0.1231	0.0783	0.1183	0.0454	0.1335	0.1821
1	10	0.1502	0.0431	0.1725	0.1515	0.116	0.1544	0.1093	0.1499	0.043	0.1749	0.0592	0.2044	0.1744
1	20	0.1528	0.0486	0.1856	0.1825	0.3136	0.1691	0.133	0.1475	0.098	0.1787	0.0803	0.1382	0.1794
5	5	0.1027	0.0676	0.2127	0.1061	2.3589	0.2132	0.0875	0.1276	0.0343	0.0868	0.4263	0.1271	0.1795
5	10	0.0879	0.0622	0.1598	0.1566	0.0788	0.123	0.0754	0.1355	0.1898	0.1799	0.1057	0.144	0.1889
5	20	0.1382	0.0902	0.0796	0.0909	0.0925	0.2199	0.0798	0.1351	0.0849	0.672	0.2297	0.1582	0.2876
10	5	0.0753	0.0671	0.1459	0.0753	0.0814	0.1295	0.0747	0.1228	0.145	0.1979	0.0499	0.1064	0.1805
10	10	0.1061	0.0475	0.0721	0.0823	0.1972	0.1168	0.0716	0.1644	0.0398	0.1174	0.0693	0.1159	0.1932

10	20	0.1146	0.143	0.2724	0.1402	0.0818	0.111	0.0733	0.1498	0.0325	0.1619	0.1204	0.212	0.1747
20	5	0.0759	0.0421	0.0758	0.0739	0.0871	0.2967	0.057	0.0769	0.0285	0.1823	0.132	0.1071	0.1895
20	10	0.0774	0.111	0.0411	0.0787	0.0957	0.1341	0.1003	0.1443	0.027	0.1758	0.0583	0.1034	0.189
20	20	0.0632	0.0988	0.0668	0.0763	0.2148	0.0959	0.1406	0.1273	0.0328	0.1321	0.1035	0.1195	0.1917
30	5	0.0947	0.0768	0.3222	0.071	0.1371	0.2553	0.052	0.1107	0.0504	0.1296	0.0809	0.1362	0.2082
30	10	0.104	0.081	0.0758	0.0716	0.0885	0.1415	0.1121	0.0718	0.0328	0.0904	0.0577	0.0977	0.1798
30	20	0.0833	0.0795	0.1118	0.1449	0.0795	0.1062	0.3365	0.0706	0.0335	0.1129	0.0899	0.1035	0.1945

MARKOV SAKLI REJİM MODELİ KULLANILARAK ELDE EDİLEN SONUÇLAR

Geçmiş Gün	Durum Param.	EFTOD	FAHES	FHEFT	FHVRH	GUMVR	HABRM	HVALE	MAASO	REZVM	SSKTA	VERGI	VRMAN	YDFON
1	2	0.1035	0.083	0.154	0.1355	0.1093	0.1051	0.1008	0.134	0.0627	0.314	0.09	0.1283	0.104
1	3	0.0969	0.097	0.152	0.1355	0.102	0.1011	0.101	0.1316	0.0627	0.273	0.094	0.1136	0.097
5	2	0.098	0.084	0.091	0.1046	0.0989	0.1168	0.0778	0.1324	0.0642	0.256	0.078	0.1268	0.098
5	3	0.0989	0.107	0.09	0.0977	0.097	0.1061	0.0796	0.1354	0.0642	0.222	0.106	0.1328	0.099
10	2	0.0833	0.096	0.07	0.0861	0.0965	0.1084	0.0678	0.1332	0.0637	0.26	0.079	0.1164	0.083
10	3	0.0736	0.087	0.071	0.0913	0.0979	0.0963	0.0685	0.1376	0.0637	0.159	0.101	0.1187	0.074
20	2	0.0709	0.08	0.06	0.0683	0.0934	0.1035	0.0559	0.101	0.0627	0.185	0.08	0.102	0.071
20	3	0.0589	0.094	0.047	0.0655	0.0931	0.099	0.0565	0.1071	0.0631	0.114	0.09	0.0992	0.059

30	2	0.0558	0.082	0.047	0.063	0.102	0.113	0.073	0.0936	0.0618	0.086	0.065	0.1122	0.056
30	3	0.063	0.09	0.051	0.0656	0.1356	0.0973	0.0585	0.0952	0.0618	0.116	0.072	0.1679	0.063

EFTOD İŞLEM TİPİ İÇİN 1. ADIM SONUÇLARI

Senaryo #	Alg. 1	Alg. 2	Alg. 3	Alg. 4	Alg. 5	Alg. 6	Alg. 7	Alg. 8	Alg. 9	Alg. 10	Alg. 11	Alg. 12	Alg. 13	Alg. 14	Alg. 15	Min. Hata
1	0.098	0.0428	0.0658	0.0946	0.0811	0.0789	0.0926	0.0985	0.0885	0.0959	0.0975	0.1016	0.1041	0.0326	0.0561	0.0326
20	0.1	0.0547	0.0722	0.094	0.0662	0.0779	0.0944	0.1043	0.0952	0.0999	0.1063	0.0884	0.0971	0.0328	0.0558	0.0328
9	0.1011	0.0921	0.0656	0.0781	0.0763	0.0839	0.0791	0.0863	0.1122	0.0911	0.0879	0.1041	0.0874	0.0346	0.0624	0.0346
2	0.098	0.0595	0.0657	0.0919	0.0631	0.0771	0.0925	0.0934	0.1058	0.0961	0.0917	0.1137	0.115	0.0361	0.0648	0.0361
10	0.1011	0.1373	0.0656	0.0923	0.0947	0.0802	0.0789	0.0808	0.0563	0.0911	0.0809	0.1033	0.104	0.0375	0.0664	0.0375
18	0.0997	0.061	0.0712	0.0957	0.0704	0.0695	0.0824	0.0857	0.1106	0.0825	0.085	0.0974	0.0709	0.0376	0.052	0.0376
7	0.1	0.0573	0.0722	0.0701	0.0693	0.08	0.0786	0.0865	0.0794	0.0921	0.0863	0.0929	0.0917	0.0397	0.0586	0.0397
21	0.0997	0.0544	0.0712	0.096	0.0954	0.0762	0.0951	0.0935	0.1097	0.0885	0.0934	0.082	0.0893	0.0397	0.0679	0.0397

17	0.1	0.0507	0.0722	0.0941	0.0497	0.0736	0.0944	0.0995	0.0798	0.0963	0.1012	0.0913	0.0962	0.0418	0.0532	0.0418
14	0.1026	0.0543	0.0778	0.1029	0.0502	0.0773	0.0978	0.0793	0.1308	0.0835	0.0792	0.0877	0.0653	0.0427	0.0597	0.0427
16	0.1021	0.074	0.0784	0.102	0.0866	0.0692	0.0839	0.0675	0.0912	0.0771	0.0711	0.0851	0.1042	0.0436	0.06	0.0436
8	0.1	0.0625	0.0722	0.0709	0.0685	0.0652	0.0784	0.0639	0.046	0.0921	0.0634	0.0893	0.085	0.045	0.0594	0.045
15	0.1021	0.0715	0.0785	0.0957	0.0861	0.0714	0.084	0.0796	0.0829	0.0771	0.0752	0.1251	0.0801	0.0463	0.0629	0.0463
13	0.1026	0.0592	0.0778	0.1043	0.0725	0.0761	0.0978	0.0803	0.0787	0.0837	0.0794	0.1129	0.0475	0.0491	0.0599	0.0475
5	0.1006	0.0584	0.0732	0.0696	0.0525	0.066	0.0762	0.0581	0.0481	0.0909	0.0625	0.0704	0.0874	0.0498	0.0503	0.0481
4	0.1	0.0603	0.0722	0.0702	0.0734	0.0664	0.0791	0.0624	0.0636	0.0922	0.0651	0.0826	0.1052	0.049	0.0533	0.049
12	0.1026	0.0614	0.0778	0.0994	0.0507	0.0751	0.0978	0.0903	0.0725	0.0838	0.087	0.1069	0.0535	0.0492	0.0588	0.0492
6	0.0998	0.0652	0.0509	0.067	0.0586	0.0721	0.093	0.0531	0.0571	0.0933	0.0575	0.0691	0.083	0.0612	0.0512	0.0509
19	0.1021	0.0759	0.057	0.0961	0.055	0.0794	0.0988	0.0966	0.171	0.0985	0.0894	0.0956	0.0873	0.0517	0.0583	0.0517
3	0.0992	0.0736	0.0668	0.0726	0.0533	0.0788	0.0805	0.0817	0.0959	0.0921	0.0812	0.086	0.0993	0.0535	0.0536	0.0533
22	0.1021	0.0636	0.0569	0.0956	0.0582	0.0785	0.0952	0.0861	0.0916	0.0891	0.0855	0.1105	0.0877	0.0547	0.0652	0.0547
11	0.1011	0.1066	0.0656	0.0986	0.088	0.0747	0.0789	0.077	0.0878	0.0911	0.0742	0.1012	0.1037	0.0559	0.0676	0.0559
0	0.098	0.096	0.096	0.0964	0.098	0.0949	0.0962	0.0959	0.1007	0.0959	0.0996	0.1551	0.0946	0.0972	0.0978	0.0946

FAHES İŞLEM TİPİ İÇİN 1. ADIM SONUÇLARI

Senaryo #	Alg. 1	Alg. 2	Alg. 3	Alg. 4	Alg. 5	Alg. 6	Alg. 7	Alg. 8	Alg. 9	Alg. 10	Alg. 11	Alg. 12	Alg. 13	Alg. 14	Alg. 15	Min. Hata
12	0.1082	0.0766	0.1037	0.0942	0.0361	0.0795	0.061	0.1056	0.1175	0.0676	0.0645	0.0965	0.1037	0.1167	0.0684	0.0361
16	0.1112	0.0391	0.0962	0.0874	0.0626	0.0695	0.0668	0.0772	0.1913	0.0688	0.0728	0.1111	0.0892	0.0948	0.0619	0.0391
2	0.0983	0.0663	0.0399	0.072	0.0463	0.0719	0.0608	0.0814	0.0606	0.0852	0.0891	0.1606	0.0802	0.0427	0.0401	0.0399
3	0.0992	0.0518	0.0513	0.0709	0.0618	0.0718	0.0614	0.0811	0.0494	0.0859	0.0896	0.1529	0.0819	0.0433	0.0441	0.0433
1	0.0981	0.0495	0.0508	0.0652	0.0668	0.0765	0.0608	0.085	0.0693	0.0852	0.0902	0.1553	0.0813	0.0735	0.0464	0.0464
5	0.101	0.0531	0.0677	0.1022	0.068	0.0828	0.0638	0.0736	0.1032	0.0883	0.0885	0.092	0.0856	0.0522	0.0482	0.0482
4	0.0999	0.0763	0.0523	0.0704	0.0498	0.0866	0.0624	0.0796	0.0624	0.0871	0.0907	0.1314	0.0845	0.0534	0.0513	0.0498
15	0.1112	0.0641	0.0925	0.0858	0.1216	0.0815	0.0668	0.065	0.1453	0.0687	0.051	0.195	0.1234	0.1215	0.0701	0.051

0	0.0981	0.0628	0.0525	0.0652	0.0569	0.0738	0.0608	0.0844	0.0641	0.0844	0.0954	0.0853	0.0588	0.0693	0.0552	0.0525
18	0.1038	0.0536	0.0858	0.0781	0.1057	0.0815	0.0774	0.0878	0.1884	0.0927	0.0904	0.1317	0.053	0.1105	0.0758	0.053
20	0.0999	0.0743	0.0807	0.0743	0.0551	0.0796	0.0724	0.0878	0.1181	0.0873	0.0934	0.1643	0.085	0.0887	0.072	0.0551
6	0.1039	0.0585	0.0697	0.079	0.074	0.0857	0.067	0.0758	0.143	0.0925	0.0833	0.0974	0.0894	0.0577	0.0589	0.0577
7	0.1	0.0601	0.0807	0.0736	0.0708	0.084	0.0724	0.0895	0.1269	0.0873	0.0938	0.1429	0.0855	0.0956	0.0691	0.0601
13	0.1082	0.1076	0.1037	0.0848	0.0703	0.0845	0.0611	0.1259	0.0937	0.0676	0.0716	0.0745	0.104	0.1092	0.0745	0.0611
14	0.1083	0.1181	0.1037	0.0836	0.0861	0.0946	0.0611	0.1164	0.0983	0.0677	0.1022	0.1058	0.096	0.1736	0.0704	0.0611
21	0.1038	0.0684	0.0858	0.0781	0.0752	0.0952	0.0774	0.0996	0.149	0.0927	0.0933	0.2128	0.0787	0.1	0.0766	0.0684
8	0.1001	0.0916	0.0807	0.0736	0.0752	0.0846	0.0724	0.0907	0.1609	0.0873	0.0947	0.1618	0.083	0.0931	0.0691	0.0691
17	0.0999	0.0825	0.0807	0.0743	0.0718	0.0797	0.0724	0.0905	0.0849	0.0873	0.0971	0.135	0.0821	0.092	0.0694	0.0694
11	0.1069	0.0952	0.1027	0.0827	0.0806	0.0852	0.0774	0.0889	0.2242	0.096	0.0977	0.0758	0.1408	0.0892	0.0752	0.0752
9	0.1069	0.0883	0.1022	0.0815	0.0949	0.0953	0.0774	0.098	0.1479	0.096	0.102	0.1663	0.0927	0.0958	0.0835	0.0774
10	0.107	0.0823	0.1022	0.0814	0.0784	0.0901	0.0774	0.0935	0.2468	0.0961	0.0919	0.1461	0.169	0.0974	0.0775	0.0774
19	0.1111	0.136	0.0924	0.0867	0.1078	0.0884	0.0821	0.1389	0.2554	0.1005	0.1003	0.0997	0.1038	0.2161	0.0863	0.0821
22	0.1112	0.1368	0.0996	0.0877	0.0924	0.1032	0.0821	0.159	0.2435	0.1005	0.1505	0.2165	0.1183	0.1198	0.0936	0.0821

FHEFT İŞLEM TİPİ İÇİN 1. ADIM SONUÇLARI

Senaryo #	Alg. 1	Alg. 2	Alg. 3	Alg. 4	Alg. 5	Alg. 6	Alg. 7	Alg. 8	Alg. 9	Alg. 10	Alg. 11	Alg. 12	Alg. 13	Alg. 14	Alg. 15	Min. Hata
17	0.1529	0.068	0.0456	0.0645	0.0469	0.0847	0.0646	0.1251	0.058	0.125	0.1429	0.0875	0.1329	0.0316	0.0362	0.0316
9	0.141	0.0691	0.0421	0.0677	0.067	0.0595	0.0671	0.082	0.0789	0.0887	0.0719	0.0725	0.0535	0.0326	0.0484	0.0326
20	0.1529	0.0545	0.0456	0.0645	0.0432	0.085	0.0646	0.1381	0.055	0.125	0.1518	0.0725	0.0923	0.0334	0.0396	0.0334
8	0.1529	0.0628	0.0456	0.0649	0.0646	0.0621	0.0646	0.0602	0.0677	0.0775	0.061	0.0782	0.0563	0.0338	0.0434	0.0338
2	0.1501	0.055	0.0511	0.0698	0.0535	0.0693	0.068	0.075	0.056	0.0916	0.0745	0.0689	0.0777	0.0339	0.0425	0.0339
1	0.1502	0.0664	0.0512	0.0694	0.0533	0.0788	0.068	0.1013	0.0982	0.1245	0.1048	0.0779	0.1039	0.0345	0.0416	0.0345
4	0.1529	0.0528	0.0456	0.0646	0.0646	0.0604	0.0646	0.0549	0.0799	0.093	0.0577	0.0659	0.0695	0.0349	0.0422	0.0349
5	0.1546	0.054	0.0462	0.0662	0.0647	0.0612	0.0655	0.0509	0.0754	0.0788	0.054	0.0565	0.0709	0.0351	0.0442	0.0351

7	0.1529	0.0637	0.0456	0.0646	0.0646	0.0651	0.0646	0.0672	0.0722	0.0778	0.0656	0.0719	0.0528	0.0352	0.0471	0.0352
18	0.1465	0.0687	0.0462	0.0637	0.0516	0.0763	0.0647	0.1073	0.0626	0.1196	0.1137	0.0752	0.1233	0.0361	0.0388	0.0361
3	0.1513	0.054	0.0483	0.0637	0.0487	0.0662	0.0637	0.064	0.0482	0.0892	0.0616	0.066	0.0679	0.0365	0.0395	0.0365
22	0.1464	0.0962	0.0405	0.0693	0.0669	0.0862	0.0686	0.135	0.0717	0.1184	0.1348	0.1344	0.0881	0.0365	0.0554	0.0365
6	0.1465	0.0468	0.0462	0.0643	0.0544	0.0641	0.0646	0.0478	0.0909	0.087	0.0566	0.053	0.0588	0.0368	0.0456	0.0368
21	0.1465	0.0545	0.0462	0.0637	0.0642	0.0751	0.0647	0.1288	0.1131	0.1196	0.1485	0.1138	0.0944	0.0369	0.0463	0.0369
13	0.1433	0.0553	0.0426	0.0687	0.0683	0.0723	0.068	0.1109	0.1056	0.1172	0.1197	0.1464	0.0689	0.0379	0.045	0.0379
16	0.1464	0.0639	0.0405	0.069	0.0514	0.078	0.0686	0.1101	0.1027	0.1185	0.108	0.1429	0.0713	0.0552	0.0551	0.0405
19	0.1464	0.0889	0.0408	0.0684	0.0535	0.0878	0.0686	0.1296	0.0909	0.1185	0.1189	0.1481	0.1223	0.0406	0.0533	0.0406
15	0.1464	0.0686	0.0408	0.068	0.0703	0.0737	0.0686	0.1136	0.0625	0.1185	0.0936	0.09	0.1029	0.0477	0.0512	0.0408
10	0.1409	0.0828	0.0421	0.0676	0.0674	0.0583	0.0673	0.0822	0.0914	0.0886	0.0706	0.0731	0.0856	0.0415	0.0546	0.0415
11	0.1409	0.0571	0.0421	0.0672	0.0617	0.0587	0.0673	0.0762	0.0495	0.0886	0.0691	0.0738	0.1054	0.0456	0.0554	0.0421
14	0.1432	0.0593	0.0426	0.0684	0.0512	0.0818	0.0678	0.1192	0.0875	0.1172	0.1393	0.1291	0.0688	0.0475	0.0462	0.0426
12	0.1432	0.0673	0.0428	0.0688	0.0602	0.0746	0.068	0.1116	0.0586	0.1171	0.0976	0.1204	0.0755	0.0503	0.0466	0.0428
0	0.1502	0.1502	0.1502	0.1505	0.1566	0.1501	0.154	0.1502	0.1499	0.1499	0.175	0.2183	0.1546	0.1674	0.1608	0.1499

FHVRH İŞLEM TİPİ İÇİN 1. ADIM SONUÇLARI

Senaryo #	Alg. 1	Alg. 2	Alg. 3	Alg. 4	Alg. 5	Alg. 6	Alg. 7	Alg. 8	Alg. 9	Alg. 10	Alg. 11	Alg. 12	Alg. 13	Alg. 14	Alg. 15	Min. Hata
14	0.1247	0.058	0.0628	0.0709	0.0437	0.0832	0.0708	0.0929	0.0749	0.11	0.0901	0.1295	0.0687	0.0499	0.0495	0.0437
9	0.1235	0.0596	0.0578	0.0705	0.0529	0.0679	0.0702	0.0715	0.156	0.0823	0.0696	0.1146	0.0769	0.0575	0.0456	0.0456
7	0.1326	0.0622	0.0633	0.0718	0.0604	0.0755	0.0718	0.075	0.0886	0.0934	0.0701	0.1081	0.059	0.0459	0.054	0.0459
17	0.1326	0.0605	0.0583	0.0715	0.0556	0.0852	0.0718	0.11	0.1166	0.1137	0.1151	0.1121	0.1324	0.0467	0.0503	0.0467
12	0.1248	0.0649	0.0585	0.0718	0.053	0.0831	0.0712	0.0917	0.0726	0.1101	0.1032	0.1402	0.0825	0.0529	0.0469	0.0469
18	0.1249	0.0638	0.0626	0.0705	0.0681	0.0788	0.0707	0.0977	0.1186	0.1074	0.0999	0.0978	0.129	0.05	0.0474	0.0474
13	0.1248	0.0508	0.0586	0.0622	0.0677	0.0794	0.0712	0.0981	0.1425	0.1102	0.0989	0.1312	0.0908	0.0499	0.0486	0.0486
15	0.1283	0.0717	0.0648	0.0731	0.0743	0.0848	0.073	0.1042	0.0894	0.1128	0.1076	0.0957	0.0918	0.0488	0.0525	0.0488

20	0.1326	0.0612	0.0583	0.0715	0.0547	0.0878	0.0718	0.1242	0.0724	0.1137	0.1272	0.0863	0.0822	0.0489	0.0527	0.0489
1	0.1301	0.0646	0.0641	0.0751	0.0575	0.0808	0.0743	0.098	0.0787	0.113	0.0997	0.1009	0.109	0.0559	0.0494	0.0494
10	0.1234	0.0674	0.0578	0.0702	0.0593	0.0648	0.0704	0.0765	0.1105	0.0821	0.0692	0.1006	0.1036	0.056	0.0498	0.0498
19	0.1283	0.069	0.0648	0.0734	0.0666	0.0921	0.073	0.1049	0.1548	0.1128	0.0987	0.141	0.1198	0.0547	0.0505	0.0505
2	0.1301	0.0592	0.0643	0.067	0.0567	0.0813	0.0743	0.0881	0.1131	0.1002	0.0886	0.094	0.0832	0.0518	0.0516	0.0516
6	0.125	0.0845	0.0636	0.0701	0.0586	0.0807	0.0705	0.0666	0.1136	0.0824	0.0671	0.0719	0.0811	0.0622	0.0517	0.0517
8	0.1326	0.061	0.0583	0.0723	0.0569	0.0737	0.0718	0.0695	0.1032	0.0933	0.0665	0.0927	0.0921	0.0549	0.0521	0.0521
21	0.1249	0.0641	0.0626	0.0705	0.067	0.0831	0.0707	0.1107	0.1994	0.1074	0.1186	0.1122	0.1006	0.0632	0.0521	0.0521
11	0.1234	0.0709	0.0578	0.072	0.0522	0.0638	0.0704	0.0761	0.1596	0.0821	0.067	0.0958	0.121	0.0575	0.0522	0.0522
3	0.1309	0.0655	0.0627	0.071	0.0702	0.0774	0.071	0.0786	0.0805	0.1013	0.08	0.089	0.089	0.0592	0.0531	0.0531
16	0.1283	0.0746	0.0657	0.0626	0.0703	0.085	0.073	0.1052	0.0937	0.1128	0.1124	0.1505	0.1154	0.0538	0.0543	0.0538
4	0.1325	0.0636	0.0583	0.0721	0.0607	0.0722	0.0719	0.0699	0.1293	0.0983	0.0699	0.0866	0.0935	0.0568	0.0539	0.0539
5	0.1342	0.0782	0.0589	0.0738	0.0619	0.0739	0.0728	0.0648	0.1043	0.0946	0.0655	0.0779	0.1157	0.064	0.0546	0.0546
22	0.1283	0.0617	0.0658	0.0735	0.0605	0.0955	0.073	0.115	0.1238	0.1128	0.1199	0.116	0.0826	0.0685	0.0568	0.0568
0	0.1301	0.1301	0.1301	0.1305	0.1265	0.1292	0.1256	0.1301	0.1398	0.1301	0.1452	0.1618	0.1274	0.1347	0.1323	0.1256

GUMVR İŞLEM TİPİ İÇİN 1. ADIM SONUÇLARI

Senaryo #	Alg. 1	Alg. 2	Alg. 3	Alg. 4	Alg. 5	Alg. 6	Alg. 7	Alg. 8	Alg. 9	Alg. 10	Alg. 11	Alg. 12	Alg. 13	Alg. 14	Alg. 15	Min. Hata
18	0.1713	0.0981	0.1415	0.1062	0.0678	0.0689	0.1052	0.0729	0.1002	0.1109	0.0795	0.0813	0.1424	0.063	0.0858	0.063
17	0.1821	0.1216	0.1698	0.1127	0.065	0.069	0.1021	0.0734	0.077	0.1092	0.0757	0.0878	0.1776	0.0675	0.0659	0.065
20	0.1821	0.0961	0.1434	0.1127	0.065	0.0678	0.1151	0.0737	0.0806	0.1121	0.0739	0.0915	0.1847	0.0752	0.065	0.065
10	0.1583	0.0821	0.134	0.0923	0.0903	0.0825	0.0816	0.0716	0.1893	0.1074	0.0656	0.0762	0.1002	0.1577	0.0708	0.0656
15	0.1547	0.1529	0.1563	0.1748	0.1543	0.0664	0.1592	0.069	0.1075	0.1087	0.0686	0.0835	0.1252	0.1235	0.1427	0.0664
11	0.1579	0.0896	0.1337	0.1076	0.0911	0.0887	0.0816	0.0699	0.1635	0.1074	0.0667	0.089	0.0966	0.1298	0.0704	0.0667
9	0.1584	0.0996	0.134	0.0858	0.091	0.0731	0.0816	0.0731	0.1092	0.1074	0.0727	0.0668	0.1143	0.1214	0.0686	0.0668
1	0.1926	0.1239	0.0957	0.1025	0.0879	0.0699	0.1139	0.0718	0.1175	0.1075	0.0731	0.0901	0.1915	0.077	0.0682	0.0682

16	0.1551	0.1336	0.1552	0.1395	0.1174	0.0738	0.1662	0.1093	0.1176	0.1087	0.0697	0.0877	0.1092	0.1136	0.1311	0.0697
7	0.1799	0.0772	0.1381	0.0954	0.1315	0.0698	0.1056	0.0743	0.0937	0.0984	0.0743	0.0899	0.1624	0.0926	0.0826	0.0698
22	0.1548	0.1101	0.1564	0.1336	0.1586	0.0702	0.1545	0.0775	0.1262	0.1087	0.0743	0.0921	0.0778	0.1426	0.118	0.0702
14	0.1547	0.087	0.1275	0.0703	0.0841	0.0874	0.0759	0.0812	0.3349	0.1061	0.0791	0.0872	0.0941	0.1472	0.082	0.0703
2	0.1899	0.0712	0.1421	0.0934	0.1764	0.0719	0.0908	0.0705	0.1216	0.0949	0.0705	0.084	0.1385	0.0839	0.0939	0.0705
12	0.1553	0.0905	0.1279	0.1064	0.1867	0.0712	0.0871	0.0779	0.1059	0.1061	0.0758	0.0817	0.1152	0.108	0.0725	0.0712
13	0.155	0.0791	0.1277	0.1071	0.0712	0.0802	0.0871	0.0775	0.1151	0.1061	0.0761	0.0848	0.0883	0.1294	0.0715	0.0712
19	0.155	0.1019	0.1289	0.093	0.1598	0.0713	0.1037	0.0782	0.1169	0.1087	0.0758	0.0899	0.1017	0.123	0.1218	0.0713
4	0.1825	0.0751	0.1398	0.1187	0.1564	0.0719	0.1056	0.074	0.0999	0.0981	0.0777	0.1051	0.1072	0.1222	0.0804	0.0719
8	0.1794	0.0776	0.1377	0.0997	0.0828	0.0721	0.1056	0.0766	0.1174	0.0984	0.0751	0.0884	0.1142	0.0932	0.0872	0.0721
3	0.1868	0.0795	0.1415	0.1536	0.0805	0.0733	0.1042	0.0746	0.1355	0.0966	0.0841	0.1012	0.1255	0.0878	0.0827	0.0733
6	0.1728	0.0766	0.084	0.1032	0.0897	0.1391	0.103	0.0742	0.1446	0.1033	0.0858	0.0907	0.0928	0.1477	0.0847	0.0742
21	0.1713	0.0784	0.1415	0.1112	0.1084	0.075	0.1109	0.0782	0.0991	0.1109	0.0791	0.088	0.1673	0.0772	0.0808	0.075
5	0.1789	0.0796	0.137	0.1149	0.1068	0.0805	0.1033	0.0753	0.1222	0.1	0.0814	0.103	0.1127	0.1156	0.0893	0.0753
0	0.1926	0.1075	0.1081	0.1559	0.1174	0.1084	0.1139	0.1075	0.1292	0.1075	0.1062	0.1359	0.1223	0.1183	0.1125	0.1062

HABRM İŞLEM TİPİ İÇİN 1. ADIM SONUÇLARI

Senaryo #	Alg. 1	Alg. 2	Alg. 3	Alg. 4	Alg. 5	Alg. 6	Alg. 7	Alg. 8	Alg. 9	Alg. 10	Alg. 11	Alg. 12	Alg. 13	Alg. 14	Alg. 15	Min. Hata
22	0.1928	0.0775	0.1889	0.1517	0.1343	0.0929	0.1698	0.0931	0.1615	0.1466	0.1138	0.0838	0.1976	0.1752	0.1244	0.0775
18	0.1995	0.0875	0.1698	0.205	0.1616	0.0801	0.1948	0.1232	0.3422	0.1571	0.1546	0.1175	0.222	0.0834	0.0976	0.0801
21	0.1995	0.1491	0.1732	0.2015	0.1917	0.0888	0.1491	0.1266	0.1502	0.1569	0.1576	0.1277	0.2379	0.0806	0.1164	0.0806
11	0.2006	0.0811	0.173	0.1636	0.1476	0.1111	0.2039	0.0973	0.1659	0.2043	0.0868	0.0956	0.2075	0.1025	0.1542	0.0811
17	0.2251	0.0825	0.1806	0.218	0.093	0.1116	0.2207	0.1574	0.1302	0.1857	0.1733	0.1409	0.2281	0.1271	0.0986	0.0825
9	0.2008	0.0839	0.1731	0.1834	0.1409	0.0878	0.1038	0.1153	0.1301	0.1277	0.1162	0.123	0.1941	0.0838	0.1313	0.0838
4	0.2252	0.084	0.1522	0.1758	0.1692	0.1429	0.128	0.0899	0.1734	0.1384	0.0857	0.1388	0.1409	0.1325	0.1075	0.084
12	0.1947	0.0842	0.1744	0.2043	0.1858	0.093	0.1913	0.1465	0.1701	0.1943	0.1783	0.087	0.2165	0.107	0.1321	0.0842

15	0.1926	0.0851	0.2106	0.1844	0.1947	0.0849	0.1799	0.1039	0.1122	0.1886	0.129	0.1018	0.1905	0.1547	0.1442	0.0849
20	0.2251	0.0857	0.1936	0.218	0.0979	0.1208	0.175	0.155	0.1308	0.1816	0.1783	0.1302	0.2247	0.1341	0.1125	0.0857
5	0.2257	0.1001	0.152	0.1813	0.1439	0.1681	0.1292	0.1	0.1335	0.1405	0.087	0.1066	0.1162	0.1271	0.1139	0.087
14	0.1947	0.1346	0.1744	0.1959	0.182	0.1221	0.1916	0.1107	0.1358	0.1945	0.1629	0.0891	0.2283	0.1135	0.1315	0.0891
8	0.2245	0.0914	0.1522	0.1787	0.1438	0.1217	0.1274	0.0909	0.1448	0.1377	0.092	0.1137	0.1776	0.1349	0.1222	0.0909
19	0.1927	0.2012	0.21	0.1819	0.1937	0.0952	0.1942	0.1063	0.1613	0.1926	0.1075	0.0917	0.2177	0.1197	0.1502	0.0917
10	0.2006	0.1425	0.173	0.1827	0.1234	0.1015	0.1037	0.102	0.1728	0.1274	0.1105	0.0928	0.1974	0.1207	0.1452	0.0928
16	0.1928	0.0939	0.1915	0.1702	0.1892	0.1023	0.1801	0.1096	0.156	0.195	0.1238	0.1116	0.1897	0.154	0.1537	0.0939
13	0.1944	0.1041	0.1742	0.1707	0.1964	0.1091	0.1912	0.1352	0.1209	0.194	0.1803	0.094	0.1958	0.1534	0.1377	0.094
7	0.2245	0.1028	0.1521	0.1755	0.1298	0.1156	0.1274	0.0972	0.173	0.1377	0.1017	0.1211	0.2001	0.1036	0.1173	0.0972
3	0.2236	0.0976	0.194	0.1701	0.1608	0.1204	0.1263	0.1009	0.2084	0.1367	0.1109	0.1333	0.134	0.1168	0.1125	0.0976
6	0.2	0.1184	0.1773	0.1511	0.1259	0.1849	0.1075	0.1337	0.2575	0.1152	0.1439	0.1411	0.1479	0.0988	0.1008	0.0988
2	0.2271	0.11	0.1851	0.1948	0.1376	0.1261	0.1467	0.1274	0.1528	0.1532	0.1419	0.1423	0.1869	0.1142	0.1229	0.11
1	0.2284	0.1269	0.1855	0.172	0.1623	0.1229	0.1467	0.1494	0.1348	0.1527	0.162	0.1249	0.2307	0.139	0.1226	0.1226
0	0.2284	0.1527	0.1731	0.1702	0.1599	0.1561	0.1467	0.1527	0.1699	0.1527	0.1621	0.1754	0.1708	0.1614	0.1559	0.1467

HVALE İŞLEM TİPİ İÇİN 1. ADIM SONUÇLARI

Senaryo #	Alg. 1	Alg. 2	Alg. 3	Alg. 4	Alg. 5	Alg. 6	Alg. 7	Alg. 8	Alg. 9	Alg. 10	Alg. 11	Alg. 12	Alg. 13	Alg. 14	Alg. 15	Min. Hata
17	0.0988	0.0565	0.0591	0.0698	0.0424	0.0658	0.0694	0.0933	0.0516	0.0985	0.1058	0.064	0.0906	0.0295	0.0417	0.0295
1	0.0971	0.0422	0.0811	0.0718	0.0386	0.0628	0.0695	0.0832	0.0513	0.0968	0.0869	0.0623	0.0916	0.0304	0.0423	0.0304
12	0.0981	0.061	0.0672	0.0717	0.0422	0.066	0.0719	0.0883	0.07	0.0986	0.0912	0.0761	0.0309	0.0414	0.057	0.0309
18	0.0971	0.0591	0.062	0.0692	0.0549	0.0648	0.0692	0.0867	0.0559	0.097	0.0886	0.0695	0.0813	0.0315	0.0462	0.0315
20	0.0988	0.0556	0.0591	0.0698	0.041	0.066	0.0694	0.1026	0.0574	0.0985	0.1118	0.0624	0.0751	0.0316	0.046	0.0316
21	0.0971	0.0646	0.062	0.0692	0.0651	0.0642	0.0692	0.0942	0.0568	0.097	0.1094	0.0683	0.0506	0.0322	0.0487	0.0322
7	0.0987	0.05	0.0591	0.0692	0.0455	0.0612	0.0764	0.0642	0.0779	0.0788	0.0653	0.0625	0.0542	0.0326	0.0513	0.0326
10	0.0969	0.0673	0.0666	0.0728	0.0771	0.0636	0.0763	0.0727	0.0643	0.0719	0.0711	0.0646	0.0757	0.033	0.0574	0.033

9	0.0968	0.0852	0.0666	0.0723	0.0867	0.0633	0.0763	0.0736	0.071	0.072	0.0674	0.0646	0.0601	0.0344	0.0551	0.0344
11	0.0969	0.0715	0.0667	0.0813	0.0465	0.0625	0.0762	0.0727	0.054	0.0718	0.071	0.0669	0.0854	0.0348	0.0564	0.0348
8	0.0987	0.0483	0.0591	0.0688	0.0431	0.0584	0.0763	0.0606	0.0436	0.0788	0.0611	0.0611	0.0775	0.0351	0.0466	0.0351
2	0.097	0.0587	0.081	0.0719	0.043	0.0619	0.0765	0.068	0.0534	0.0771	0.0688	0.0592	0.0866	0.0356	0.046	0.0356
13	0.0981	0.0471	0.0671	0.0722	0.0393	0.0656	0.0719	0.0913	0.0527	0.0944	0.0857	0.0818	0.0359	0.0432	0.0546	0.0359
5	0.0995	0.0519	0.0786	0.0697	0.0501	0.0591	0.0746	0.0508	0.0475	0.0783	0.0538	0.0596	0.0769	0.0367	0.0443	0.0367
4	0.0987	0.0518	0.0771	0.0691	0.0505	0.0595	0.0764	0.0529	0.055	0.0789	0.0541	0.0582	0.0778	0.0379	0.0463	0.0379
14	0.0981	0.0695	0.0671	0.0722	0.05	0.07	0.0718	0.0856	0.0649	0.0941	0.0932	0.0901	0.0399	0.0496	0.0518	0.0399
3	0.0978	0.0624	0.0814	0.0682	0.0641	0.0625	0.0756	0.0624	0.0993	0.0783	0.0649	0.0583	0.078	0.0408	0.0451	0.0408
6	0.0971	0.0556	0.0821	0.0813	0.0694	0.0628	0.0757	0.0518	0.0598	0.0797	0.0548	0.062	0.0855	0.0451	0.0501	0.0451
19	0.1011	0.0537	0.0687	0.0734	0.0655	0.076	0.0728	0.1024	0.0838	0.1008	0.0946	0.1042	0.078	0.0465	0.0614	0.0465
22	0.1011	0.0683	0.0693	0.0728	0.0685	0.0753	0.0728	0.0953	0.054	0.0888	0.0827	0.0966	0.0724	0.0502	0.0589	0.0502
15	0.1011	0.0659	0.0686	0.0732	0.0697	0.0714	0.0728	0.0982	0.0703	0.1008	0.0876	0.082	0.0852	0.0529	0.0639	0.0529
16	0.1011	0.0535	0.0694	0.073	0.0795	0.07	0.0728	0.0926	0.0632	0.093	0.0863	0.0928	0.0667	0.0531	0.0652	0.0531
0	0.0971	0.0967	0.1006	0.097	0.1049	0.0968	0.0983	0.0967	0.097	0.0967	0.116	0.1342	0.0994	0.1042	0.1032	0.0967

MAASO İŞLEM TİPİ İÇİN 1. ADIM SONUÇLARI

Senaryo #	Alg. 1	Alg. 2	Alg. 3	Alg. 4	Alg. 5	Alg. 6	Alg. 7	Alg. 8	Alg. 9	Alg. 10	Alg. 11	Alg. 12	Alg. 13	Alg. 14	Alg. 15	Min. Hata
17	0.138	0.0662	0.0837	0.109	0.0453	0.1027	0.1074	0.1067	0.0712	0.1236	0.1069	0.082	0.101	0.0454	0.0352	0.0352
1	0.1461	0.0744	0.0871	0.0783	0.0444	0.104	0.1041	0.1054	0.0685	0.1136	0.1116	0.152	0.1215	0.0427	0.0359	0.0359
9	0.1439	0.1199	0.081	0.1156	0.0553	0.1036	0.1125	0.1218	0.095	0.1359	0.133	0.1907	0.1099	0.0486	0.0376	0.0376
10	0.1439	0.0638	0.0811	0.1153	0.0462	0.0936	0.1125	0.1012	0.0842	0.1199	0.1095	0.1665	0.1106	0.0561	0.0382	0.0382
20	0.138	0.0687	0.0972	0.0846	0.0482	0.0838	0.0937	0.0947	0.0608	0.1001	0.102	0.116	0.0682	0.0477	0.0387	0.0387
6	0.1401	0.0684	0.084	0.113	0.0582	0.0865	0.0807	0.0631	0.0391	0.0929	0.0764	0.0484	0.0409	0.0444	0.0514	0.0391
21	0.14	0.0603	0.1017	0.0888	0.0546	0.0671	0.0678	0.0695	0.0624	0.0745	0.0684	0.1042	0.0794	0.0516	0.0396	0.0396
8	0.1376	0.0516	0.0837	0.1142	0.0464	0.0887	0.1072	0.094	0.0641	0.1187	0.1026	0.1577	0.1149	0.0457	0.0401	0.0401

19	0.1489	0.0561	0.0756	0.1183	0.0404	0.1005	0.1184	0.0964	0.1019	0.1228	0.0928	0.1612	0.123	0.0504	0.0587	0.0404
2	0.1461	0.0582	0.088	0.0792	0.0617	0.0994	0.1043	0.107	0.0689	0.1136	0.1125	0.1423	0.1187	0.0584	0.0406	0.0406
22	0.1485	0.0736	0.0946	0.1092	0.0406	0.0697	0.0828	0.0574	0.1019	0.0839	0.0519	0.073	0.0599	0.0615	0.0446	0.0406
11	0.144	0.0862	0.0812	0.1128	0.0412	0.0849	0.0852	0.0832	0.0634	0.0955	0.0925	0.1326	0.0723	0.0604	0.0421	0.0412
7	0.1376	0.0579	0.0837	0.0824	0.0508	0.1	0.1072	0.1088	0.0825	0.1294	0.1232	0.1838	0.1401	0.0429	0.043	0.0429
12	0.1455	0.1079	0.0809	0.1137	0.0696	0.098	0.1029	0.092	0.097	0.1208	0.1097	0.1192	0.0943	0.0525	0.0429	0.0429
15	0.1487	0.1046	0.0756	0.118	0.0432	0.1087	0.1086	0.1059	0.1535	0.1123	0.1196	0.2039	0.1257	0.0498	0.0518	0.0432
18	0.14	0.06	0.0797	0.1117	0.0648	0.0973	0.1003	0.0855	0.1582	0.1041	0.094	0.1265	0.098	0.0467	0.0449	0.0449
4	0.1381	0.0711	0.0837	0.1093	0.0458	0.0871	0.1076	0.0872	0.0843	0.1146	0.1003	0.1459	0.1162	0.0645	0.045	0.045
3	0.1369	0.1118	0.0822	0.1145	0.048	0.0944	0.1057	0.1084	0.0895	0.1134	0.1132	0.1467	0.1016	0.0539	0.0455	0.0455
14	0.1452	0.1112	0.0799	0.0856	0.049	0.1075	0.1166	0.094	0.103	0.1208	0.1149	0.1279	0.0581	0.0464	0.0532	0.0464
5	0.1396	0.0553	0.0845	0.117	0.066	0.0799	0.1076	0.0761	0.0736	0.0944	0.0887	0.1436	0.1196	0.058	0.0482	0.0482
13	0.1454	0.089	0.0799	0.116	0.0744	0.1047	0.1166	0.0941	0.0817	0.1206	0.1146	0.1301	0.1188	0.0502	0.0483	0.0483
16	0.1485	0.0881	0.0756	0.149	0.1216	0.1041	0.109	0.0965	0.1991	0.1126	0.1043	0.1239	0.1159	0.0779	0.0594	0.0594
0	0.1461	0.1136	0.1154	0.1152	0.1169	0.1146	0.1134	0.1136	0.1355	0.1136	0.1172	0.1582	0.1176	0.127	0.119	0.1134

REZVM İŞLEM TİPİ İÇİN 1. ADIM SONUÇLARI

Senaryo #	Alg. 1	Alg. 2	Alg. 3	Alg. 4	Alg. 5	Alg. 6	Alg. 7	Alg. 8	Alg. 9	Alg. 10	Alg. 11	Alg. 12	Alg. 13	Alg. 14	Alg. 15	Min. Hata
2	0.0938	0.0258	0.0291	0.064	0.0409	0.0333	0.0297	0.0252	0.0225	0.0303	0.0268	0.0383	0.0409	0.029	0.0338	0.0225
17	0.0902	0.0767	0.0796	0.0522	0.0417	0.0303	0.0423	0.027	0.0239	0.0418	0.0277	0.04	0.0788	0.0386	0.0362	0.0239
7	0.0886	0.0426	0.0623	0.0556	0.0342	0.0346	0.0452	0.0256	0.0242	0.0442	0.026	0.0393	0.0379	0.0483	0.0386	0.0242
21	0.082	0.0293	0.0513	0.0664	0.0303	0.0302	0.0506	0.0244	0.0277	0.0468	0.0256	0.0385	0.0359	0.0487	0.0352	0.0244
8	0.0882	0.0323	0.062	0.0746	0.0448	0.0391	0.0452	0.0247	0.0494	0.0443	0.0263	0.0358	0.0294	0.055	0.0391	0.0247
20	0.0902	0.0316	0.0871	0.0606	0.0348	0.03	0.0378	0.0247	0.029	0.0382	0.0254	0.0373	0.0783	0.0469	0.0386	0.0247
5	0.0872	0.025	0.0312	0.0524	0.0414	0.0486	0.0301	0.0253	0.045	0.0311	0.026	0.0377	0.0379	0.0668	0.0297	0.025
3	0.0922	0.026	0.0289	0.0685	0.0305	0.0352	0.0298	0.0256	0.0333	0.0305	0.0266	0.0366	0.0345	0.03	0.0305	0.0256

4	0.0905	0.026	0.0293	0.0626	0.0429	0.0435	0.0302	0.0261	0.0337	0.0309	0.0269	0.0425	0.0367	0.0465	0.0306	0.026
1	0.096	0.0267	0.0535	0.0634	0.0322	0.0306	0.0297	0.0262	0.0389	0.03	0.0269	0.0377	0.0855	0.0297	0.0323	0.0262
6	0.0828	0.0268	0.0319	0.056	0.0343	0.0563	0.0299	0.0271	0.0432	0.0315	0.0288	0.0437	0.0316	0.0735	0.0316	0.0268
22	0.0683	0.0343	0.0756	0.0546	0.0337	0.0332	0.0392	0.027	0.0392	0.042	0.0291	0.0402	0.0351	0.044	0.0351	0.027
16	0.0685	0.0305	0.0766	0.0517	0.0412	0.0362	0.0651	0.0292	0.0462	0.0534	0.0274	0.0328	0.0312	0.0387	0.0346	0.0274
18	0.082	0.0375	0.0691	0.0695	0.0357	0.0308	0.0499	0.0285	0.0459	0.0434	0.0299	0.0393	0.0455	0.0387	0.0383	0.0285
0	0.096	0.03	0.0323	0.0634	0.0331	0.0336	0.0297	0.03	0.0324	0.03	0.029	0.0334	0.0427	0.0311	0.0313	0.029
14	0.0695	0.0357	0.0582	0.0661	0.0442	0.0397	0.0413	0.0368	0.0695	0.0439	0.0303	0.0452	0.0415	0.0476	0.0397	0.0303
12	0.0701	0.0476	0.0587	0.0514	0.0385	0.0323	0.0413	0.0315	0.0574	0.0439	0.0305	0.0433	0.0387	0.044	0.0323	0.0305
13	0.0697	0.0401	0.0584	0.0701	0.0594	0.0357	0.0413	0.0358	0.0457	0.0437	0.0305	0.0443	0.041	0.0499	0.0349	0.0305
9	0.0709	0.0314	0.0709	0.0489	0.037	0.0332	0.0744	0.0357	0.0627	0.0533	0.0354	0.0438	0.0347	0.051	0.0403	0.0314
15	0.0689	0.0316	0.0803	0.051	0.0381	0.0331	0.0694	0.0349	0.041	0.0534	0.0344	0.0417	0.0452	0.0331	0.037	0.0316
19	0.0691	0.0389	0.0804	0.0432	0.0351	0.0344	0.0472	0.0321	0.0438	0.0469	0.033	0.0457	0.0424	0.0494	0.0375	0.0321
10	0.0709	0.0432	0.0709	0.0503	0.0375	0.035	0.0422	0.0357	0.0376	0.046	0.0334	0.0441	0.0344	0.0587	0.0421	0.0334
11	0.071	0.0372	0.071	0.0432	0.0393	0.037	0.0373	0.0348	0.0585	0.0425	0.0344	0.0445	0.037	0.0666	0.0406	0.0344

SSKTA İŞLEM TİPİ İÇİN 1. ADIM SONUÇLARI

Senaryo #	Alg. 1	Alg. 2	Alg. 3	Alg. 4	Alg. 5	Alg. 6	Alg. 7	Alg. 8	Alg. 9	Alg. 10	Alg. 11	Alg. 12	Alg. 13	Alg. 14	Alg. 15	Min. Hata
6	0.1553	0.0421	0.1135	0.0499	0.0365	0.0989	0.0671	0.092	0.0751	0.0623	0.0991	0.0404	0.0078	0.0781	0.0665	0.0078
8	0.1479	0.1011	0.0798	0.1496	0.0101	0.1113	0.0642	0.1469	0.0322	0.1571	0.1448	0.1917	0.1412	0.0803	0.0424	0.0101
21	0.1549	0.0106	0.0699	0.0487	0.0517	0.0654	0.0605	0.059	0.0511	0.0748	0.082	0.0399	0.0185	0.0748	0.0442	0.0106
11	0.1616	0.0848	0.0744	0.0983	0.0588	0.091	0.068	0.0938	0.0141	0.0638	0.0961	0.1542	0.1887	0.0636	0.064	0.0141
0	0.1448	0.0594	0.0879	0.1442	0.0349	0.1123	0.12	0.1482	0.245	0.1482	0.146	0.0142	0.0972	0.0187	0.0318	0.0142
12	0.1637	0.0839	0.0756	0.0683	0.0628	0.1112	0.0682	0.106	0.127	0.1678	0.1197	0.1468	0.02	0.0641	0.0618	0.02
22	0.1689	0.0662	0.0586	0.0635	0.0561	0.0942	0.0842	0.0447	0.02	0.0719	0.0777	0.0362	0.075	0.1173	0.0795	0.02
2	0.1449	0.1597	0.1045	0.0625	0.1372	0.1048	0.0664	0.1311	0.0431	0.1309	0.1323	0.1928	0.0201	0.0574	0.0505	0.0201

13	0.1637	0.0229	0.1054	0.043	0.1412	0.1117	0.0683	0.1134	0.1425	0.1678	0.1179	0.1468	0.0202	0.0621	0.0535	0.0202
14	0.1637	0.1371	0.1054	0.0564	0.0484	0.1117	0.0683	0.1174	0.07	0.1678	0.1182	0.1468	0.0202	0.0612	0.0502	0.0202
10	0.1616	0.0729	0.0744	0.0531	0.0217	0.1039	0.068	0.1551	0.0834	0.1739	0.1635	0.1525	0.171	0.0822	0.0583	0.0217
20	0.1481	0.0256	0.066	0.0495	0.0519	0.0593	0.0648	0.0675	0.059	0.0715	0.0841	0.0377	0.1104	0.0588	0.039	0.0256
4	0.1482	0.0301	0.1157	0.0637	0.0401	0.0927	0.068	0.1042	0.1354	0.1345	0.1047	0.185	0.1326	0.071	0.0526	0.0301
1	0.1448	0.0406	0.0937	0.1307	0.0528	0.1073	0.0663	0.1333	0.0433	0.1308	0.1377	0.1928	0.1052	0.042	0.0343	0.0343
3	0.1465	0.1401	0.1059	0.1079	0.0416	0.1046	0.0673	0.126	0.0414	0.1327	0.1268	0.1953	0.1079	0.0554	0.0414	0.0414
16	0.1689	0.0414	0.163	0.1701	0.1311	0.1118	0.0842	0.1055	0.1411	0.1483	0.141	0.1601	0.1445	0.0659	0.0935	0.0414
7	0.1479	0.0628	0.0798	0.0497	0.0424	0.104	0.0641	0.1343	0.0531	0.1337	0.1424	0.1367	0.1327	0.078	0.0509	0.0424
17	0.1481	0.0821	0.066	0.0495	0.051	0.1119	0.0648	0.1323	0.1893	0.1117	0.1014	0.1973	0.1207	0.1088	0.0424	0.0424
5	0.1497	0.0703	0.107	0.0586	0.064	0.083	0.065	0.0834	0.0514	0.0647	0.0997	0.139	0.17	0.0612	0.0439	0.0439
18	0.1549	0.1097	0.0699	0.0487	0.0799	0.1254	0.0605	0.1064	0.0875	0.1378	0.1184	0.1966	0.1221	0.1042	0.0646	0.0487
15	0.1689	0.1322	0.1529	0.0523	0.155	0.1273	0.0841	0.134	0.1452	0.1483	0.1438	0.2311	0.1559	0.1007	0.1022	0.0523
9	0.1616	0.0525	0.0744	0.066	0.0627	0.114	0.068	0.1366	0.1504	0.1484	0.1618	0.1551	0.1473	0.1206	0.053	0.0525
19	0.1689	0.0681	0.0693	0.1427	0.0549	0.1418	0.0841	0.1195	0.1605	0.1542	0.1529	0.2739	0.0959	0.1513	0.1046	0.0549

VERGİ İŞLEM TİPİ İÇİN 1. ADIM SONUÇLARI

Senaryo #	Alg. 1	Alg. 2	Alg. 3	Alg. 4	Alg. 5	Alg. 6	Alg. 7	Alg. 8	Alg. 9	Alg. 10	Alg. 11	Alg. 12	Alg. 13	Alg. 14	Alg. 15	Min. Hata
4	0.1053	0.0429	0.0347	0.0813	0.0494	0.0925	0.0762	0.096	0.0553	0.0953	0.0928	0.2153	0.0075	0.039	0.0452	0.0075
6	0.1086	0.0386	0.0285	0.0987	0.0946	0.1016	0.0808	0.0979	0.2014	0.1008	0.0993	0.1699	0.0092	0.0457	0.0691	0.0092
3	0.1052	0.0628	0.0215	0.0721	0.0381	0.0921	0.0743	0.095	0.0623	0.0945	0.0948	0.1258	0.0097	0.0432	0.0382	0.0097
5	0.1065	0.0562	0.0352	0.0897	0.0257	0.096	0.0769	0.0875	0.0753	0.0966	0.0945	0.1683	0.0106	0.0502	0.0476	0.0106
15	0.1164	0.024	0.106	0.0596	0.0561	0.0458	0.0418	0.0322	0.0613	0.0337	0.0165	0.1222	0.1156	0.0366	0.0407	0.0165
2	0.1042	0.0213	0.0212	0.0718	0.0833	0.0971	0.0734	0.0951	0.137	0.0934	0.0938	0.2738	0.0245	0.0568	0.0438	0.0212
12	0.1127	0.0338	0.1051	0.0352	0.0572	0.0834	0.0366	0.0488	0.108	0.0379	0.0224	0.1003	0.1132	0.0421	0.0476	0.0224
7	0.1054	0.0743	0.0859	0.0812	0.026	0.0939	0.0846	0.0952	0.1505	0.0954	0.0973	0.1734	0.0244	0.0794	0.0785	0.0244

16	0.1165	0.0352	0.1151	0.0358	0.1002	0.0422	0.0418	0.0439	0.0903	0.0338	0.0258	0.1489	0.0885	0.063	0.0447	0.0258
14	0.1129	0.1033	0.1001	0.1104	0.0483	0.1036	0.0366	0.0636	0.1423	0.038	0.0281	0.1206	0.1117	0.0519	0.0507	0.0281
13	0.1128	0.0583	0.0479	0.1141	0.0827	0.0862	0.0366	0.0535	0.1367	0.038	0.0284	0.1039	0.1131	0.0814	0.046	0.0284
1	0.1039	0.0517	0.0332	0.079	0.0319	0.0938	0.0734	0.094	0.0404	0.0934	0.0947	0.2534	0.0866	0.0553	0.0369	0.0319
0	0.1039	0.0457	0.0548	0.079	0.0465	0.0862	0.0734	0.1003	0.0993	0.1003	0.0992	0.1005	0.0589	0.0532	0.0486	0.0457
17	0.1053	0.0581	0.0859	0.0834	0.0888	0.0942	0.0846	0.0976	0.1759	0.0954	0.0987	0.1536	0.11	0.0892	0.0824	0.0581
20	0.1053	0.0627	0.0859	0.0834	0.0869	0.0996	0.0846	0.0962	0.1645	0.0954	0.0973	0.2593	0.0986	0.0842	0.0814	0.0627
8	0.1055	0.0657	0.0798	0.0814	0.0844	0.0994	0.0846	0.0955	0.1215	0.0954	0.0968	0.2332	0.0781	0.0849	0.0648	0.0648
18	0.1086	0.0993	0.1144	0.0864	0.0953	0.0797	0.0893	0.0916	0.2755	0.1014	0.0942	0.124	0.1514	0.0917	0.0901	0.0797
19	0.1163	0.1084	0.124	0.0833	0.1148	0.1011	0.0983	0.0981	0.1836	0.1103	0.1064	0.1054	0.0865	0.1146	0.0964	0.0833
11	0.1117	0.2007	0.0854	0.0974	0.1073	0.105	0.0928	0.1042	0.2162	0.1058	0.1091	0.1128	0.1631	0.1014	0.0972	0.0854
21	0.1086	0.1168	0.1144	0.1078	0.1479	0.1082	0.0893	0.1081	0.1832	0.1014	0.1018	0.1489	0.1294	0.1307	0.0993	0.0893
10	0.1118	0.11	0.1025	0.0901	0.097	0.1049	0.0928	0.1042	0.2456	0.1057	0.1087	0.2626	0.1092	0.1023	0.0933	0.0901
9	0.1117	0.111	0.1023	0.0906	0.101	0.1038	0.0927	0.1037	0.0955	0.1056	0.1088	0.2377	0.1371	0.0958	0.0967	0.0906
22	0.1165	0.1326	0.1074	0.0954	0.1162	0.1083	0.1211	0.1304	0.2529	0.1366	0.1139	0.1498	0.1194	0.1556	0.1187	0.0954

VRMAN İŞLEM TİPİ İÇİN 1. ADIM SONUÇLARI

Senaryo #	Alg. 1	Alg. 2	Alg. 3	Alg. 4	Alg. 5	Alg. 6	Alg. 7	Alg. 8	Alg. 9	Alg. 10	Alg. 11	Alg. 12	Alg. 13	Alg. 14	Alg. 15	Min. Hata
6	0.1292	0.0804	0.0654	0.1129	0.0589	0.1002	0.1126	0.0841	0.0611	0.1008	0.0886	0.0499	0.0266	0.0523	0.0638	0.0266
14	0.1325	0.0409	0.0728	0.115	0.0733	0.1039	0.1148	0.1115	0.1168	0.1124	0.1213	0.1369	0.1287	0.0665	0.0528	0.0409
5	0.1297	0.0443	0.0864	0.1125	0.0413	0.0852	0.1102	0.0839	0.0593	0.1099	0.0895	0.0972	0.1355	0.0569	0.0503	0.0413
2	0.1273	0.0589	0.0907	0.0844	0.0533	0.0859	0.1086	0.1196	0.0487	0.1281	0.1338	0.0997	0.1386	0.0429	0.0499	0.0429
3	0.1285	0.1002	0.0909	0.1082	0.0444	0.0863	0.1085	0.1104	0.0595	0.1313	0.1203	0.1031	0.1041	0.0513	0.0488	0.0444
4	0.13	0.0815	0.0862	0.1091	0.0601	0.0855	0.1099	0.0982	0.0743	0.1096	0.1047	0.0758	0.0928	0.046	0.0502	0.046
1	0.1274	0.0466	0.0906	0.0864	0.0577	0.087	0.1088	0.1196	0.0899	0.1204	0.1268	0.1039	0.134	0.0554	0.0489	0.0466
8	0.1296	0.0631	0.0862	0.1098	0.0479	0.0851	0.1094	0.1014	0.1296	0.1086	0.1055	0.1064	0.1145	0.0523	0.0514	0.0479

11	0.131	0.0503	0.0734	0.1169	0.061	0.0874	0.115	0.0963	0.1005	0.1048	0.1005	0.0726	0.1055	0.0552	0.0577	0.0503
20	0.1298	0.0601	0.0862	0.1105	0.0522	0.0817	0.1098	0.1228	0.0581	0.123	0.13	0.1057	0.1018	0.057	0.0503	0.0503
13	0.1326	0.1031	0.0728	0.1145	0.0516	0.1004	0.1148	0.1152	0.1228	0.1124	0.1314	0.135	0.0962	0.0621	0.0516	0.0516
7	0.1296	0.0772	0.0862	0.109	0.0631	0.0909	0.1094	0.1092	0.1225	0.1086	0.1114	0.1112	0.1197	0.0529	0.055	0.0529
12	0.1325	0.0577	0.0733	0.1143	0.0599	0.0965	0.1148	0.122	0.083	0.113	0.1345	0.1251	0.1381	0.053	0.0576	0.053
17	0.1298	0.0595	0.0862	0.1105	0.0635	0.0876	0.1098	0.1206	0.1092	0.123	0.1218	0.1088	0.1073	0.0552	0.0535	0.0535
22	0.135	0.0543	0.0676	0.0779	0.0809	0.0896	0.1175	0.092	0.0864	0.0967	0.0864	0.0865	0.1253	0.0634	0.069	0.0543
19	0.1351	0.0733	0.0703	0.1172	0.1164	0.1046	0.1175	0.1266	0.0646	0.1193	0.1224	0.108	0.1155	0.0572	0.0742	0.0572
18	0.1287	0.0981	0.0835	0.1117	0.0811	0.0905	0.1124	0.1117	0.0881	0.112	0.1126	0.1059	0.1317	0.0574	0.0588	0.0574
10	0.1311	0.0959	0.0734	0.1136	0.0635	0.0919	0.115	0.1064	0.0595	0.1048	0.1082	0.0763	0.1015	0.0601	0.0575	0.0575
9	0.1311	0.0783	0.0741	0.1154	0.0604	0.0955	0.115	0.1116	0.0749	0.1048	0.1117	0.1285	0.1059	0.0588	0.0587	0.0587
21	0.1287	0.0611	0.0835	0.1117	0.1162	0.0746	0.1124	0.099	0.0814	0.1227	0.0981	0.0793	0.0933	0.0635	0.0644	0.0611
16	0.135	0.1089	0.0699	0.1177	0.1051	0.0971	0.1176	0.0954	0.1301	0.1151	0.0972	0.1511	0.128	0.0666	0.0615	0.0615
15	0.1354	0.1075	0.069	0.1167	0.1117	0.0993	0.1169	0.1129	0.1084	0.1145	0.1167	0.1509	0.1318	0.0678	0.0658	0.0658
0	0.1274	0.1134	0.1171	0.1244	0.1158	0.1223	0.1177	0.1222	0.14	0.1222	0.1229	0.1692	0.116	0.1228	0.1186	0.1134

YDFON İŞLEM TİPİ İÇİN 1. ADIM SONUÇLARI

Senaryo #	Alg. 1	Alg. 2	Alg. 3	Alg. 4	Alg. 5	Alg. 6	Alg. 7	Alg. 8	Alg. 9	Alg. 10	Alg. 11	Alg. 12	Alg. 13	Alg. 14	Alg. 15	Min. Hata
17	0.1755	0.2428	0.202	0.1761	0.1659	0.217	0.1747	0.1762	0.3624	0.1875	0.1748	0.2203	0.2104	0.1808	0.1796	0.1659
20	0.1755	0.2229	0.202	0.1761	0.1659	0.2252	0.1747	0.1762	0.4568	0.1875	0.175	0.2872	0.2301	0.1803	0.1764	0.1659
1	0.1744	0.1829	0.1744	0.1796	0.218	0.2074	0.1806	0.1837	0.3226	0.184	0.1812	0.2629	0.2369	0.1671	0.1729	0.1671
21	0.1817	0.1944	0.1841	0.1818	0.1709	0.2251	0.18	0.1861	0.4238	0.1969	0.1843	0.3176	0.2288	0.2001	0.1732	0.1709
3	0.174	0.1965	0.1713	0.2081	0.1928	0.2044	0.1931	0.1871	0.4683	0.1831	0.185	0.2538	0.2407	0.1935	0.1855	0.1713
18	0.1817	0.2063	0.1841	0.1818	0.1718	0.2111	0.18	0.1917	0.402	0.1969	0.1916	0.243	0.2041	0.2793	0.1979	0.1718
8	0.1757	0.1805	0.2022	0.1818	0.1974	0.2206	0.1947	0.1793	0.5373	0.1852	0.1736	0.3599	0.225	0.2138	0.1855	0.1736
0	0.1744	0.184	0.1794	0.1805	0.1809	0.1841	0.1806	0.184	0.182	0.184	0.18	0.1792	0.1775	0.1792	0.1777	0.1744

2	0.1746	0.1906	0.1997	0.1843	0.2071	0.2016	0.1941	0.1882	0.3901	0.1839	0.1929	0.2485	0.2457	0.1814	0.1924	0.1746
5	0.1779	0.1978	0.1748	0.2298	0.2005	0.1901	0.1982	0.1991	0.4161	0.1876	0.1788	0.29	0.2366	0.2713	0.192	0.1748
4	0.1755	0.2104	0.202	0.2094	0.1889	0.2005	0.194	0.1973	0.4513	0.1848	0.1827	0.2621	0.2792	0.2146	0.1885	0.1755
7	0.1756	0.1817	0.2021	0.2287	0.1956	0.2234	0.1945	0.1822	0.4092	0.185	0.1876	0.3173	0.2139	0.2109	0.1797	0.1756
11	0.1903	0.2023	0.1843	0.19	0.1762	0.2148	0.1892	0.2092	0.4674	0.2058	0.2074	0.2811	0.2259	0.222	0.1836	0.1762
15	0.1987	0.1934	0.1925	0.1992	0.2056	0.2149	0.1952	0.2365	0.2041	0.2117	0.2568	0.2298	0.1934	0.2116	0.1774	0.1774
14	0.1938	0.181	0.1881	0.1943	0.1934	0.2107	0.1939	0.2133	0.6058	0.1925	0.2679	0.2975	0.2125	0.2429	0.1842	0.181
6	0.1814	0.2102	0.1839	0.2538	0.2022	0.1829	0.1999	0.2088	0.2863	0.1898	0.2186	0.2924	0.2359	0.3412	0.1914	0.1814
13	0.194	0.2243	0.1887	0.1996	0.1978	0.222	0.1947	0.2115	0.9265	0.2087	0.2252	0.2867	0.2099	0.2253	0.1829	0.1829
22	0.1983	0.1925	0.2042	0.2	0.2025	0.2085	0.1953	0.2246	0.4076	0.1922	0.2551	0.2598	0.2166	0.2369	0.184	0.184
9	0.1901	0.232	0.1843	0.1941	0.1996	0.2343	0.1887	0.2107	0.3827	0.2058	0.2185	0.2465	0.2444	0.1994	0.1884	0.1843
10	0.1901	0.1968	0.1843	0.1965	0.1884	0.2264	0.1887	0.2093	0.5335	0.2058	0.2124	0.2654	0.2606	0.2398	0.1848	0.1843
19	0.1985	0.1868	0.1925	0.1891	0.2018	0.2129	0.1953	0.2355	0.3407	0.2117	0.2923	0.2685	0.2364	0.232	0.2044	0.1868
12	0.1936	0.1922	0.1877	0.197	0.1996	0.2268	0.1927	0.2178	0.384	0.2087	0.2045	0.2574	0.2081	0.235	0.187	0.187
16	0.1984	0.2031	0.1954	0.2041	0.1936	0.2195	0.1955	0.2351	0.3577	0.2117	0.2656	0.3004	0.2029	0.2216	0.1894	0.1894

SENARYOLARIN HER BİR İŞLEM TİPİNDE KAÇINCI OLDUĞU VE ORTALAMASI BİLGİSİ

Senaryo #	EFTOD (67)	FAHES (67)	FHEFT (67)	FHVRH (67)	GUMVR (65)	HABRM (65)	HVALE (67)	MAASO (67)	REZVM (67)	SSKTA (67)	VERGI (63)	VRMAN (65)	YDFON (67)	Ort.	Kullanıldığı İşlem Tipi sayısı
17	12.	53.	1.	4.	3.	19.	3.	2.	5.	43.	45.	21.	14.	17.3077	13
20	2.	46.	3.	11.	3.	24.	8.	10.	9.	31.	47.	17.	14.	17.3077	13
2	4.	33.	5.	17.	17.	36.	16.	19.	3.	22.	24.	8.	23.	17.4615	13
1	1.	38.	6.	12.	10.	46.	4.	4.	17.	38.	34.	13.	15.	18.3077	13
245 (17+ zaman farkı)	-	-	41.	-	5.	-	27.	6.	32.	-	-	-	4.	19.1667	6
7	10.	49.	9.	3.	13.	33.	11.	23.	6.	43.	26.	19.	26.	20.8462	13

8	15.	52.	4.	19.	21.	28.	15.	16.	9.	11.	48.	15.	21.	21.0769	13
6	23.	48.	13.	18.	26.	35.	28.	12.	18.	8.	15.	2.	32.	21.3846	13
18	7.	44.	10.	7.	1.	16.	7.	27.	22.	45.	49.	24.	19.	21.3846	13
4	21.	41.	7.	24.	20.	21.	19.	28.	16.	35.	11.	11.	25.	21.4615	13
12	22.	29.	24.	6.	18.	22.	5.	23.	28.	21.	25.	20.	38.	21.6154	13
21	10.	51.	14.	19.	28.	17.	10.	15.	7.	12.	52.	30.	17.	21.6923	13
14	13.	50.	22.	1.	16.	27.	22.	32.	27.	23.	31.	6.	31.	23.1538	13
3	27.	35.	11.	22.	23.	34.	25.	29.	15.	40.	16.	9.	18.	23.3846	13
5	20.	39.	8.	25.	29.	25.	18.	36.	12.	44.	18.	7.	24.	23.4615	13
9	3.	57.	2.	2.	8.	20.	13.	7.	30.	47.	54.	27.	36.	23.5385	13
10	6.	57.	20.	13.	4.	30.	12.	8.	36.	24.	53.	25.	36.	24.9231	13
11	29.	56.	21.	20.	7.	18.	14.	20.	37.	15.	51.	17.	27.	25.5385	13
13	19.	50.	15.	9.	18.	32.	17.	37.	28.	23.	32.	18.	34.	25.5385	13
15	18.	42.	19.	10.	6.	23.	37.	24.	31.	46.	23.	32.	28.	26.0769	13
22	28.	58.	11.	29.	15.	13.	34.	19.	19.	21.	55.	22.	35.	27.6154	13
24 (17+ zaman	-	-	25.	-	35.	-	21.	47.	29.	-	-	-	9.	27.6667	6

farkı)															
16	14.	32.	16.	23.	12.	31.	38.	53.	21.	40.	28.	31.	39.	29.0769	13
249 (17+ zaman farkı)	-	-	39.	-	11.	-	42.	59.	26.	-	-	-	1.	29.6667	6
243 (17+ zaman farkı)	-	-	26.	-	32.	-	23.	46.	14.	-	-	-	43.	30.6667	6
19	25.	58.	17.	15.	19.	29.	29.	17.	33.	49.	50.	23.	37.	30.8462	13
244 (17+ zaman farkı)	-	-	43.	-	24.	-	26.	30.	20.	-	-	-	45	31.3333	6
242 (17+ zaman farkı)	-	-	55.	-	42.	-	58.	1.	52.	-	-	-	30	39.6667	6
247 (17+ zaman farkı)	-	-	37.	-	38.	-	53.	42.	49.	-	-	-	20	39.8333	6
0	54.	43.	56.	61.	36.	59.	60.	61.	23.	16.	43.	54.	22	45.2308	13
241 (17+ zaman farkı)	-	-	53.	-	44.	-	54.	38.	40.	-	-	-	46	45.8333	6

240 (17+ zaman farkı)	-	-	28. -		50. -		48.	48.	57. -	-	-		51	47.0000	6
246 (17+ zaman farkı)	-	-	40. -		48. -		50.	56.	54. -	-	-		41	48.1667	6

ÖZGEÇMİŞ

KİŞİSEL BİLGİLER

Adı Soyadı : Seyhan AMASYALI
Doğum Tarihi ve Yeri : 08.03.1980 - Fatih
Yabancı Dili : İngilizce
E-posta : seyhanamasyali@gmail.com

ÖĞRENİM DURUMU

Derece	Alan	Okul/Üniversite	Mezuniyet Yılı
Lisans	Bilgisayar Mühendisliği	Yıldız Teknik Üniversitesi	2001
Lise	Fen-Matematik	Pertevniyal Lisesi	1997

İŞ TECRÜBESİ

Yıl	Firma/Kurum	Görevi
2002-2010	Garanti Teknoloji A.Ş.	Yazılım Uzmanı
2002	Aknet A.Ş.	Yazılım Mühendisi
2001	Sesam Yazılım Hizmetleri Ltd. Şti.	Yazılım Mühendisi

YAYINLARI

Bildiri

1. İşler S., Amasyalı M. F., Tatlı E., (2000), “Bir Türkçe Metindeki Kelimelerin Cümle İçindeki Durumlarına Bakılarak Eklerine Ayrılması ”, Bilişim Zirvesi'01, İstanbul.