



YAPAY SİNİR AĞLARI İLE HİSSE SENEDİ KAPANIŞ FİYATLARININ TAHMİNİ VE
PORTFÖY OPTİMİZASYONU

Merve ŞİŞCİ

Yüksek Lisans Tezi

Endüstri Mühendisliği Anabilim Dalı

Haziran – 2017

YAPAY SİNİR AĞLARI İLE HİSSE SENEDİ KAPANIŞ FİYATLARININ TAHMİNİ VE
PORTFÖY OPTİMİZASYONU

Merve ŞİŞCİ

Dumlupınar Üniversitesi
Lisansüstü Eğitim Öğretim ve Sınav Yönetmeliği Uyarınca
Fen Bilimleri Enstitüsü Endüstri Mühendisliği Anabilim Dalında
YÜKSEK LİSANS TEZİ
Olarak Hazırlanmıştır.

Danışman: Doç. Dr. Özden ÜSTÜN

Haziran - 2017

KABUL VE ONAY SAYFASI

Merve ŐIŐCI'nin YÜKSEK LİSANS tezi olarak hazırladığı 'Yapay Sinir Ağları ile Hisse Senedi Kapanıő Fiyatlarının Tahmini ve Portföy Optimizasyonu' başlıklı bu alıőma, jürimizce Dumlupınar Üniversitesi Lisansüstü Eğitim Öğretim ve Sınav Yönetmeliğinin ilgili maddeleri uyarınca deęerlendirilerek kabul edilmiőtir.

21/06/2017

Üye : Do. Dr. Özden ÜSTÜN (Danıőman)

Üye : Do. Dr. Őafak KIRIŐ

Üye : Do. Dr. Ezgi AKTAR DEMİRTAŐ

Fen Bilimleri Enstitüsü Yönetim Kurulu'nun/...../2017 gün ve sayılı kararıyla onaylanmıőtır.

Prof. Dr. Hasan GÖÇMEZ
Fen Bilimleri Enstitüsü Müdürü

ETİK İLKE VE KURALLARA UYGUNLUK BEYANI

Bu tezin hazırlanmasında Akademik kurallara riayet ettiğimizi, özgün bir çalışma olduğunu ve yapılan tez çalışmasının bilimsel etik ilke ve kurallara uygun olduğunu, çalışma kapsamında teze ait olmayan veriler için kaynak gösterildiğini ve kaynaklar dizininde belirtildiğini, Yüksek Öğretim Kurulu tarafından kullanılmak üzere önerilen ve Dumlupınar Üniversitesi tarafından kullanılan İntihal Programı ile tarandığını ve benzerlik oranının % 7 çıktığını beyan ederiz. Aykırı bir durum ortaya çıktığı takdirde tüm hukuki sonuçlara razı olduğumuzu taahhüt ederiz.

Doç. Dr. Özden ÜSTÜN

İmza

Merve ŞİŞCİ

İmza

YAPAY SİNİR AĞLARI İLE HİSSE SENEDİ KAPANIŞ FİYATLARININ TAHMİNİ VE PORTFÖY OPTİMİZASYONU

Merve ŞİŞÇİ

Endüstri Mühendisliği, Yüksek Lisans Tezi, 2017

Tez Danışmanı: Doç. Dr. Özden ÜSTÜN

ÖZET

Modern portföy teorisinde, yatırım araçlarını çeşitlendirmenin yatırım risklerini azalttığı kabul edilen bir gerçektir. Yatırımcı doğal olarak piyasada maruz kaldığı riske karşın en büyük getiriyi elde etmek istemektedir. Yatırım, gelecekle ilgili bir süreç olduğundan doğal olarak belirsizlikler ve riskler içermektedir. Portföy optimizasyonu üzerine yapılan çalışmalarda genellikle geçmişe dayalı getiri değerleri kullanılmıştır. Bu çalışmanın amacı, tahminleme yöntemlerine göre Markowitz'in ortalama-varyans modelinin performansını analiz etmektir. Çalışmada BIST 30 'da işlem gören 26 hisse senedine ait 2008-2014 yılları arasındaki aylık kapanış değerleri kullanılmıştır. En iyi tahmin aracının bulunması için Yapay Sinir Ağları ve Zaman Serileri Analizi Yöntemleri karşılaştırılmıştır. İlk olarak, Yapay Sinir Ağlarının en iyi parametre değerlerinin bulunması amaçlanmıştır. Tahminler gerçekleştirilmeden önce farklı zaman dilimleri, nöron sayıları, girdi değişkeni sayıları ve öğrenme algoritmaları kullanılarak tahminleme modelleri oluşturulmuştur. Bu modellerin tahmin sonuçları karşılaştırılırken MAE, MSE, MAPE hata ölçümleri kullanılmıştır. İkinci aşamada, 2008-2013'e ait aylık ortalama kapanış fiyatlarından hareketle Basit Ortalama, Hareketli Ortalamalar, Üstel Düzeltme ve Trend Analizi Yöntemleri kullanılarak 2014'e ait 12 aylık kapanış fiyatları tahmin edilip Yapay Sinir Ağı Sonuçları ile karşılaştırılmıştır. Sonuçlara göre en iyi tahmin değerlerini veren yöntemlerin Yapay Sinir Ağları ve Üstel Düzeltme yöntemleri olduğu tespit edilmiştir. Bu iki yöntemin tüm hisse senetlerinde birbirlerine üstünlük sağlamadıkları görülmüştür. Son olarak, Yapay Sinir Ağları, Üstel Düzeltme ve geçmiş gerçek veriler kullanılarak oluşturulan Markowitz'in Ortalama-Varyans modellerinin farklı beklenen getiri düzeylerindeki eniyi varyans değerleri, 2014 yılına ait gerçek varyans değerleri kullanılarak karşılaştırılmıştır. Hesaplama sonuçlarına göre, birleştirilmiş Yapay Sinir Ağları-Üstel Düzeltme tahmin yöntemi ile Markowitz'in Ortalama-Varyans modelinin birlikte kullanılması ile en iyi sonucun elde edildiği görülmüştür.

Anahtar Kelimeler: Portföy Optimizasyonu, Tahminleme, Yapay Sinir Ağları, Zaman Serileri Analizi.

STOCK PRICES FORECASTING WITH ARTIFICIAL NEURAL NETWORKS AND PORTFOLIO OPTIMIZATION

Merve ŞİŞÇİ

Industrial Engineering, M.Sc. Thesis, 2017

Supervisor: Assoc. Prof. Dr. Özden ÜSTÜN

SUMMARY

In the modern Portfolio Theory, minimization of investment risks through diversification of investment tools is a widely adopted notion. Investors seek to obtain maximum profit against the risk they encounter. Investments inherently involve uncertainties and risks as they are dependent on future. Retroactive returns data have been widely used in portfolio optimization studies. The aim of this study was to analyze the performance of Markowitz's mean-variance model. Accordingly, monthly returns values of 26 stock exchange securities traded in ISE-30 within 2008-2014 period were used. Artificial Neural Networks (ANN) and Time-Series Analysis Methods were compared to find the best forecasting tool. Determination of the best parameter values of ANN and the most suitable time period for forecasting was aimed. Different time periods, different number of neurons, input variables and learning algorithms were used to build the models. MAE, MSE and MAPE error measurement methods were used to compare the results. Afterwards, Simple Average Method, Moving Averages Method, Exponential Smoothing and Trend Analysis Methods were used to obtain annual returns forecasting for 2014 on the basis of monthly average returns for 2008-2013, and the results were compared with ANN results. ANN and Exponential Smoothing methods yielded the most accurate results. These two methods displayed no certain advantage over each other. Finally, by use of ANN, Exponential Smoothing and real historical data, the best variance values were compared using real variance values of 2014. Accordingly, the best portfolio optimization outcome was obtained by combined use of ANN-Exponential Smoothing method and Markowitz's Mean-Variance model.

Keywords: Portfolio Optimization, Forecasting, Artificial Neural Networks, Time-Series Analysis.

TEŞEKKÜR

Çalışmanın planlanmasından teslim aşamasına gelinceye kadar görüşleriyle teze yön veren, engin bilgi ve tecrübesiyle rehberliğini hiçbir zaman esirgemeyen tez danışmanım ve çok değerli hocam Doç. Dr. Özden ÜSTÜN'e, sağladığı huzurlu ve birlik içindeki çalışma ortamı ve çalışma azmi aşıl原因 için Bölüm Başkanımız ve değerli hocam Doç. Dr. Şafak KIRIŞ'a, değerli vaktini ayırarak tez sınav jürimde yer alan saygıdeğer hocam Doç. Dr. Ezgi AKTAR DEMİRTAŞ'a, sevgisi ve anlayışıyla hep yanımda olan, zor zamanlarımda desteğiyle beni hiç yalnız bırakmayan eşim Evren ŞİŞÇİ'ye, sevgisini her zaman hissettiren hayattaki en değerli varlığım, kızım Zeynep Ece ŞİŞÇİ'ye, bugünlere gelmemi sağlayan çok sevdiğim annem Şükran ÖGE ve babam Halil İbrahim ÖGE'ye en içten sevgi, saygı ve şükranlarımı sunar, teşekkür etmeyi bir borç bilirim.

İÇİNDEKİLER

	<u>Sayfa</u>
ÖZET	v
SUMMARY	vi
ŞEKİLLER DİZİNİ.....	xii
ÇİZELGELER DİZİNİ	xiii
SİMGELER VE KISALTMALAR DİZİNİ	xiv
1. GİRİŞ	1
2. MARKOWITZ'İN ORTALAMA-VARYANS MODELİ	12
2.1. Portföy Kuramı	12
2.2. Portföy Optimizasyonu	12
2.3. Portföy İle İlgili Temel Kavramlar.....	14
2.3.1. Dönemlik getiri	14
2.3.2. Ortalama getiri	14
2.3.3. Sapma ölçütleri (varyans ve standart sapma (risk))	15
2.3.4. Kovaryans	15
2.4 Portföy Teorileri	16
2.4.1. Geleneksel Portföy Teorisi.....	16
2.4.2. Modern Portföy Teorisi.....	16
2.5. Portföyün Getirisi ve Riski.....	20
2.5.1. Risk ve beklenen getiri ilişkisi.....	20
2.5.2. n varlıktan oluşan portföyün beklenen getirisi ve riski.....	22
2.6. Optimum Portföy	22
3. TAHMİN YÖNTEMLERİ	25
3.1. Zaman Serileri Analizi	27
3.1.1. Trend Analizi.....	28
3.1.2. Basit Ortalamalar Yöntemi	30
3.1.3. Hareketli Ortalamalar Yöntemi.....	30
3.1.4. Üstel Düzeltme Yöntemi.....	30
3.2. Yapay Zeka ve Sezgisel Algoritmalar	32
4. YAPAY SİNİR AĞLARI.....	33

İÇİNDEKİLER (devam)

	<u>Sayfa</u>
4.1. YSA'nın Tanımı.....	33
4.2. YSA'nın Uygulama Alanları	35
4.3. YSA'nın Avantajları ve Dezavantajları	36
4.4. Biyolojik Sinir Hücresinin Yapısı	38
4.5. Yapay Sinir Hücresinin Yapısı.....	40
4.5.1. Girdiler.....	41
4.5.2. Ağırlıklar.....	41
4.5.3. Toplama fonksiyonu.....	42
4.5.4. Aktivasyon fonksiyonu	43
4.5.5. Çıktı	44
4.6. Yapay Sinir Ağlarının Sınıflandırılması	44
4.6.1. YSA'ların yapılarına göre sınıflandırılması	44
4.6.1.1. İleri beslemeli ağlar	45
4.6.1.2. Geri beslemeli ağlar.....	46
4.6.2. YSA'ların öğrenme algoritmalarına göre sınıflandırılması.....	46
4.6.2.1. Danışmanlı öğrenme.....	47
4.6.2.2. Danışmansız öğrenme	48
4.6.2.3. Destekli öğrenme.....	48
4.6.3. Uygulamaya göre öğrenme algoritmaları	49
4.6.3.1. Çevrimiçi (online) öğrenme	49
4.6.3.2. Çevrimdışı (offline) öğrenme	49
4.7. YSA Öğrenme Algoritmaları.....	50
4.7.1. Temel öğrenme kuralları	50
4.7.2. Öğrenme algoritmaları.....	51
4.7.2.1. Geri yayılım algoritması.....	51
4.7.2.2. Levenberg Marquardt Geri Yayılım Algoritması.....	52
4.7.2.3. Bayesyen Düzeltme (Bayesian Regularization) Geri Yayılım Algoritması	53
4.8. YSA Modelleri	54
5. TAHMİN PERFORMANSI ÖLÇME TEKNİKLERİ.....	57
5.1. Hata Büyüklüğü Doğruluğu	57
5.2. Ortalama Mutlak Hata (MAE)	58
5.3. Hata Kareleri Ortalaması (MSE).....	58
5.4. Hata Kareleri Ortalamasının Kökü (RMSE).....	59
5.5. Ortalama Mutlak Yüzde Hata (MAPE).....	59
5.6. Theil U İstatistiği.....	60
6. BIST 30'DA YER ALAN HİSSE SENETLERİNİN AYLIK KAPANIŞ FİYATI TAHMİNLERİ İÇİN PORTFÖY OPTİMİZASYONU TEMELLİ KARŞILAŞTIRMA UYGULAMASI.....	61

İÇİNDEKİLER (devam)

Sayfa

6.1. Veri Analizi.....	65
6.2. Hisse Senedi Kapanış Fiyatlarının Tahminlenmesi	68
6.2.1. Yapay Sinir Ağları ile tahminleme	68
6.2.1.1. Veri ön işleme ve normalizasyon.....	68
6.2.1.2. Tahminlerin gerçekleştirilmesi	69
6.2.2. Zaman Serileri Yöntemleri ile tahminleme.....	78
6.2.2.1. Basit Ortalama Yöntemi ile tahminleme	79
6.2.2.2. Hareketli Ortalamalar Yöntemi ile tahminleme.....	79
6.2.2.3. Üstel Düzeltme Yöntemi ile tahminleme.....	80
6.2.2.4. Trend Analizi Yöntemi ile tahminleme.....	81
6.3. Tahmin Hatalarının Karşılaştırılması (Varyans Analizi – Tek Yönlü ANOVA).....	84
6.4. Tahminlerin Birleşimi İçin Farklı Modeller Temelli Portföy Optimizasyonu.....	87
6.4.1. Mevcut veriler ile tahmin verilerinin Markowitz'in Ortalama-Varyans Modeli yardımıyla karşılaştırılması.....	87
6.4.2. Modellere ait beklenen getiri, varyans ve kovaryans değerlerinin hesaplanması	90
6.4.3. Modellerin tanımlı olduğu en küçük ve en büyük beklenen getiri değerlerinin hesaplanması.....	90
6.4.4. Modeller için farklı beklenen getiri seviyelerine göre varyansların hesaplanması ..	92
6.4.5. Modellere ait varyansların gerçek verilere ait varyanslara göre mutlak hatalarının varyans analizi (tek yönlü ANOVA)	97
7. SONUÇLAR VE ÖNERİLER	100
KAYNAKLAR DİZİNİ.....	102
EKLER	
ÖZGEÇMİŞ	

ŞEKİLLER DİZİNİ

<u>Sekil</u>	<u>Sayfa</u>
2.1. Portföy Optimizasyonu süreci.....	13
2.2. MPT yatırım süreci.	17
2.3. Portföy risk ve getirisi: iki varlıklı durum	21
2.4. Ortalama-varyans portföy verimliliği.	24
3.1. Tahmin yöntemleri.....	26
3.2. Ticari ve ekonomik veriler için tipik desenler gösteren dört zaman serisi.....	28
3.3. Örnek satış eğilimi grafiği	29
4.1. YSA ile gerçekleştirilebilecek görevler	35
4.2. Biyolojik bir nöron.....	39
4.3. Bir nöron modeli	40
4.4. Ağırlıklı girdi toplamı	42
4.5. Aktivasyon fonksiyonu çeşitleri	43
4.6. İleri-geri besleme ve tekrarlayan / geribildirim ağ mimarisinin bir taksonomisi.....	45
4.7. İleri-beslemeli bir ağ.....	46
4.8. Danışmanlı öğrenme blok diyagramı; şeklin mavi renk ile gösterilen kısmı bir geri besleme döngüsü oluşturur.....	47
4.9. Delta öğrenme kuralı.....	51
4.10. Çok katmanlı ileri beslemeli sinir ağı	56
6.1. Uygulama akış şeması.....	63
6.2. AKBANK hisse senedine ait kapanış fiyatlarının normal eğri ile birlikte verilen histogramı	67
6.3. AKBANK hisse senedine ait kapanış fiyatlarının normal grafiği.....	68
6.4. Bağımlı değişkenin (5. ay) tahmininde kullanılan ağ yapısı.....	70
6.5. Model 2'ye göre yöntemlerin seçilme sayıları.....	88
6.6. Model 3'e göre yöntemlerin seçilme sayıları.....	89
6.7. Model 1'in belirlenen beklenen getiri düzeylerindeki varyans değerleri ve Model 0'a ait varyans değerleri	94
6.8. Model 2'nin belirlenen beklenen getiri düzeylerindeki varyans değerleri ve Model 0'a ait varyans değerleri	95
6.9. Model 3'ün belirlenen beklenen getiri düzeylerindeki varyans değerleri ve Model 0'a ait varyans değerleri	96
6.10. Model 4'ün belirlenen beklenen getiri düzeylerindeki varyans değerleri ve Model 0'a ait varyans değerleri	97

ÇİZELGELER DİZİNİ

<u>Cizelge</u>	<u>Sayfa</u>
1.1. Tahminleme yöntemlerinden yararlanılarak yapılan Portföy Optimizasyonu çalışmaları.....	3
3.1. İlgili verilerin altında yatan zaman birimi temel alınarak tahmin türlerinin kategorize edilmesi	25
4.1. Nöronlar ve işleme elemanları (PE)nın benzerlikleri.....	41
4.2. Bilinen öğrenme algoritmaları	54
6.1. Hisse senetlerinin 2008-2013 yılları arasındaki aylık kapanış değerlerinin dağılımına ilişkin istatistikler ve normal dağılım testi sonuçları (N=72).....	65
6.2. Kullanılan ağın parametreleri.....	69
6.3. Yapay Sinir Ağlarıyla tahminlemede karşılaştırılan ağ yapıları	71
6.4. AKBANK hisse senedi için YSA 1 ile 2012 yılı için tahmin edilen değerler ve gerçek değerler.....	72
6.5. AKBANK hisse senedi için YSA 2 ile 2013 yılı için tahmin edilen değerler ve gerçek değerler.....	72
6.6. AKBANK hisse senedi için YSA 3 ile 2014 yılı için tahmin edilen değerler ve gerçek değerler.....	73
6.7. Yıllara ve nöron sayılarına göre Yapay Sinir Ağı uygulaması performans sonuçları.....	73
6.8. AKBANK hisse senedi için YSA 4 ile 2014 yılı için tahmin edilen değerler ve gerçek değerler.....	74
6.9. Yıllara ve nöron sayılarına göre Yapay Sinir Ağı uygulaması performans sonuçları.....	74
6.10. AKBANK hisse senedi için YSA 5 ile 2014 yılı için tahmin edilen değerler ve gerçek değerler.....	75
6.11. Yıllara ve nöron sayılarına göre yapay sinir ağı uygulaması performans sonuçları	76
6.12. Yıllara ve nöron sayılarına göre Yapay Sinir Ağı uygulaması performans sonuçları.....	76
6.13. AKBANK hisse senedi için YSA 3 ile saklı katmandaki 5-10-15-20 nöron sayıları için tahmin edilen değerler ve gerçek değerler (normalize edilmiş değerler tahmin çalışmasından sonra kendi ölçeklerine çevrilmiştir)	77
6.14. AKBANK hisse senedi için YSA 5 ile saklı katmandaki 5-10-15-20 nöron sayıları için tahmin edilen değerler ve gerçek değerler (normalize edilmiş değerler tahmin çalışmasından sonra kendi ölçeklerine çevrilmiştir)	78
6.15. Basit Ortalama Yöntemi ile tahmin edilen değerler ve gerçek değerler	79
6.16. Hareketli Ortalamalar Yöntemi ile tahmin edilen değerler ve gerçek değerler.....	80
6.17. Üstel Düzeltme Yönteminin α katsayısı 0.9 ile 2014 yılı için tahmin edilen değerler ve gerçek değerler	80
6.18. Trend Analizi Yöntemi ile tahmin edilen değerler ve gerçek değerler	81
6.19. Karşılaştırılan yöntemlerden elde edilen MAPE sonuçları	82
6.20. Varyans analizi çeşitleri	84

ÇİZELGELER DİZİNİ (devam)

<u>Çizelge</u>	<u>Sayfa</u>
6.21. MAPE değişkenine göre tanımlayıcı istatistikler.....	85
6.22. Varyansların homojenliği testi	85
6.23. ANOVA sonuçları.....	85
6.24. Tamhane Testi çoklu karşılaştırmalar	86
6.25. Model 2 ve Model 3 ile elde edilen MAPE değerleri	89
6.26. Modellere ait eniyi portföyün enküçük ve enbüyük beklenen getiri değerleri.....	92
6.27. Model 1'in belirlenen beklenen getiri düzeylerindeki varyans değerleri ve Model 0'a ait varyans değerleri.....	93
6.28. Model 2'nin belirlenen beklenen getiri düzeylerindeki varyans değerleri ve Model 0'a ait varyans değerleri.....	94
6.29. Model 3'ün belirlenen beklenen getiri düzeylerindeki varyans değerleri ve Model 0'a ait varyans değerleri.....	95
6.30. Model 4'ün belirlenen beklenen getiri düzeylerindeki varyans değerleri ve Model 0'a ait varyans değerleri.....	96
6.31. Mutlak hata değişkenine göre tanımlayıcı istatistikler.....	98
6.32. Varyansların homojenliği testi	98
6.33. ANOVA sonuçları.....	98
6.34. Tamhane Testi çoklu karşılaştırmalar	99

SİMGELER VE KISALTMALAR DİZİNİ

Simgeler

R_{it}	i hisse senedinin t dönemindeki getiri oranı
P_{it}	i hisse senedinin t dönemindeki kapanış fiyatı
μ_i	i varlığının ortalama getirisi
T	Toplam dönem sayısı
$var(R_i)$	i varlığının getirisinin varyansı
σ_{ij}	i ve j varlıkları arasındaki kovaryans değerini
$Cov(R_i, R_j)$	İki menkul kıymetin getirilerinin kovaryansı
N	Mevcut varlık sayısı
x_i	i. varlığın portföy içerisindeki oranını gösteren karar değişkenlerini
\hat{Y}_t	Tahmini kapanış değeri
a	Regresyon denklemindeki sabit
b	Regresyon denklemindeki katsayı
X	Bağımsız değişken
F_t	Tahmin değeri
α	Düzeltilme faktörü
n	Hareketli Ortalamalar Yönteminde ortalama için seçilen dönem sayısı
Net	Net girdi
W_i	Nörona bağlı ağırlık faktörü
X_i	Nöronun girdisi
F_t	t. zaman periyodundaki tahmin değeri
A_t	t. zaman periyodundaki tahmin edilen değişkenin gerçek değeri
e_t	t. zaman periyodundaki tahmin hatası
Δ	Aralık

Alt İndisler

i	Hisse senedi
j	Hisse senedi
t	Dönem

Açıklamalar

SİMGELER VE KISALTMALAR DİZİNİ (devam)

<u>Kısaltmalar</u>	<u>Açıklamalar</u>
BIST 30	Borsa İstanbul Kurumsal Ürünler Pazarı'nda İşlem Gören 30 Hisse Senedi
MPT	Modern Portföy Teorisi
OV	Ortalama-Varyans
YSA	Yapay Sinir Ağları
MLP	Multi Layer Perceptron
ÇKA	Çok Katmanlı Algılayıcı
LM	Levenberg-Marquardt
BR	Bayesian Regularization
MAE	Ortalama Mutlak Hata
MSE	Hata Kareleri Ortalaması
RMSE	Hata Kareleri Ortalamasının Kökü
MAPE	Ortalama Mutlak Yüzde Hata
MAG.	Mağazaları
HLD.	Holding
THY	Türk Hava Yolları
INS	İnşaat
T. HALK BNK.	Türkiye Halk Bankası
Enk	Enküçük
Enb	Enbüyük
W	Shapiro-Wilk-W Testi
sig.	Anlamlılık
k.a.	Koşulları Altında
Std.	Standart

1. GİRİŞ

Küreselleşen Dünya, yatırımcılara getiri ve risk açısından çok sayıda cazip seçenekler sunmaktadır. İletişim ağları ve bankalar, piyasaların takibini ve sermayenin etkin yatırım araçlarına yönlendirilmesini kolaylaştırmaktadır. Sunduğu cazip seçenekler ve küresel altyapısı ile şirketlerin hisse senetlerinin işlem gördüğü borsalar, popüler bir yatırım kanalı haline gelmiştir.

Portföy optimizasyonu, matematik, istatistik, finans ve yöneylem araştırması literatüründe üzerinde çok çalışılan bir problemdir. Portföy optimizasyonu, çıktılarını seçilen bir veya birden fazla ölçüte göre en üst düzeye çıkaracak şekilde bileşenlerini yönetme sürecidir. Bir portföyde tutulan finansal varlıklarla ilişkili ağırlıkların eniyi birleşiminin belirlenmesine bağlıdır. Daha yüksek getiri elde etmek ve aynı zamanda riski azaltmakla ilgili yatırım problemi, çok karmaşık ve eniyi çözümünün belirlenmesi zor bir sorundur. Bilim adamları ve mühendisler, çok düşük insan müdahalesi ile kararlar alarak portföyleri yönetmek için algoritmalar yaratmak üzere istatistiksel yöntemler ile yapay zeka araçlarını kullanmaktadırlar. Portföy optimizasyonu için kullanılan veriler de değişkenlik göstermektedir. Bazı çalışmalarda gerçek veriler kullanılırken, bazı araştırmacılar geçmiş verilerden hareketle tahmin edilen verileri kullanmayı tercih etmektedirler. Küreselleşen dünyada internet altyapısı sayesinde çok farklı yatırım araçlarına kolaylıkla yatırım yapmak mümkün hale gelmiştir. Yatırımda yer alacak araçların gelecek dönem getirilerini yüksek doğrulukla tahmin edecek yöntemlere olan ihtiyaç gün geçtikçe artmaktadır. Yatırım araçlarının getirileri, hem küresel hem de yerel ekonomik sistemler içerisindeki bileşenlerden etkilenen dinamik bir değişkendir. Araştırmacılar, yatırımcıların portföylerini eniyileme ihtiyaçlarını karşılayabilmek için yoğun bir çaba sarf etmektedirler.

Borsa piyasalarında son dönemde gündemi yoğun bir biçimde meşgul eden yüksek frekanslı işlemler (High-Frequency Trading / HFT); milisaniyeler gibi kısa sürelerde belirli algoritmalara dayanarak, çok yüksek hızlarda hisse senedi alım satımı yapan otomatik bilgisayar işlemlerini ifade etmektedir. Alım satım işlemlerine bilgisayarlar karar vermekte, çok kısa sürelerde çok sayıda işlem gerçekleşmektedir. Algoritmik finansal kararların oluşturduğu yüksek frekanslı işlem ortamının her geçen gün genişlediği görülmektedir (<http://www.finansofisi.com>). ABD’de hisse senedi işlem hacminin %60’dan fazlası HFT emirleriyle oluşmaktadır. Bu oran Avrupa’da %50’ye varırken, Japonya’da henüz %30 civarındadır (<http://kanalfinans.com>). Farklı ülkelerde pek çok uzman, kamu yöneticisi, savcı ve

güvenlik yetkilisi bu işlemlerin yasal olmadığını veya piyasa koşullarını zorladığını belirtse de şu ana kadar uygulamaya giren bir regülasyon olmamıştır. Bu yapı, aslında yeni finans ve yeni normal olarak kabul görmelidir. Yüksek volatilité, yüksek hacimler ve düşük karlar yeni normaldir. İnsan bazlı, manuel işlemler ve yüksek karların oluşturduğu yapı gittikçe sona yaklaşmaktadır. Finans kuruluşları bu tür uygulamalar için gerekli altyapı ve insan kaynağı yatırımlarını tamamlamalıdır (http://www.finansofisi.com).

Bu bölümde literatürde bulunan 205 adet portföy optimizasyonu çalışması incelenmiş olup bu çalışmalardan yirmi bir tanesinde portföy optimizasyonu modelinde kullanılmak üzere getiriler için tahminleme yöntemi kullanıldığı belirlenmiştir. Çizelge 1.1'de tahminleme yöntemlerinden yararlanılarak yapılan portföy optimizasyonu çalışmalarını gerçekleştiren yazarlar, çalışmaların yayınlandıkları yıl, gerçekleştirilme amaçları, hisse senedi getirileri için kullanılan tahminleme yöntemi, varsa bu tahminleme yönteminin performansının karşılaştırıldığı diğer tahminleme yöntemleri, portföy optimizasyonunun gerçekleştirilmesinde kullanılan model veya yöntem, portföy optimizasyonu modeli veya yönteminin karşılaştırıldığı diğer yöntemler gösterilmektedir. Çalışmalar incelendiğinde portföy optimizasyonu yöntemi olarak en çok Ortalama Getiri-Varyans Portföy Optimizasyonu modelinin kullanıldığı, tahminleme yöntemi olarak ise en çok Yapay Sinir Ağları, ARMA (Oto regresif Hareketli Ortalama) modeli ve GARCH (Genelleştirilmiş Oto regresif Koşullu Varyans) modelinin kullanıldığı görülmektedir. Steiner ve Wittkemper (1997), Freitas vd. (2009), Gunasekaran ve Ramaswami (2014) ve Mishra, Panda and Majhi (2016) Yapay Sinir Ağlarıyla çalışmayı tercih etmişlerdir. Bu çalışmada, tahminleme yöntemi olarak Yapay Sinir Ağları kullanıldığı için Çizelge 1.1'de Yapay Sinir Ağları yardımıyla hisse senedi kapanış fiyatları tahmini yapılarak gerçekleştirilen portföy optimizasyonu çalışmaları açıklanmıştır.

Çizelge 1.1. Tahminleme yöntemlerinden yararlanılarak yapılan Portföy Optimizasyonu çalışmaları.

Yazar	Yıl	Amaç	Tahmin Yöntemi	Karşılaştırılan Tahmin Yöntemi	Optimizasyon Yöntemi	Karşılaştırılan Optimizasyon Yöntemi
Steiner ve Wittkemper	1997	Günlük ticarete dayalı bir portföy yapısı optimizasyonu için bir model tanımlamak ve geliştirmek	Genelleştirilmiş Regresyon Sinir Ağı	-	Düzenli Piyasalar Hipotezi	-
Gohout ve Specht	2007	Tahminlere dayalı klasik Ortalama-Varyans (OV) portföylerinin optimal portföy ağırlıklarını hesaplamak	Bayesci Vektör Otoregresyon Modeli	-	Klasik Ortalama-Varyans Portföy Optimizasyonu	-
Gülpınar ve Rüstem	2007	Birden fazla rakip getiri ve risk senaryosuna sahip en kötü durum tasarımına çok dönemli Ortalama-Varyans optimizasyonu altyapısı geliştirmek	Simülasyon Tabanlı Senaryo Ağaç Oluşturma Yöntemi	-	Ortalama-Varyans Portföy Optimizasyonu	Enküçük - Enbüyük Optimizasyonu
Freitas vd.	2009	Kısa vadeli yatırım fırsatlarını yakalayabilen tahmine dayalı yeni bir portföy optimizasyonu modeli sunmak	Otoregresif Sinir Ağları (ARNN)	-	Tahmin Tabanlı Portföy Optimizasyonu Modeli	Markowitz'in Ortalama-Varyans Modeli
Üstün ve Kasımbeyli	2012	Portföy seçimi problemi için birleştirilmiş tahminleri kullanan genel bir matematiksel model sunmak	Otoregresif Bütünleşik Hareketli Ortalama (ARIMA), Üstel Düzeltme ve Zaman Serisi Ayırıştırma	-	Genişletilmiş Ortalama-Varyans-Çarpıklık Modeli ve F-MSG (Uygun Değerler Temelli Genelleştirilmiş Subgradient) Algoritması	-
Leung vd.	2012	Optimal portföy getirisi tahmini için açık formüller elde etmek	Yansız Tahmin (The Unbiased Estimators)	Plug-in Tahmin, Bootstrap-Düzeltilmiş Tahmin	Markowitz'in Ortalama-Varyans Modeli Optimizasyonu	-
Ayan ve Akay	2013	Modern Portföy Teorisinin beklenen getiri ve risk tanımlarını yeniden ele alarak alternatif yaklaşım geliştirmektir.	ARIMA Modeli	-	Kuadratik Programlama	Modern Portföy Teorisi
Matmoura ve Penev	2013	Portföy optimizasyonunun dinamik ortamlarda ve uygulamalardaki avantajlarını göstermek	GARCH Model	-	Stokastik Programlama	-

Çizelge 1.1. Tahminleme yöntemlerinden yararlanılarak yapılan Portföy Optimizasyonu çalışmaları (devamı).

Yazar	Yıl	Amaç	Tahmin Yöntemi	Karşılaştırılan Tahmin Yöntemi	Optimizasyon Yöntemi	Karşılaştırılan Optimizasyon Yöntemi
Pekkaya ve Albayrak	2013	FI (Kesirli Bütünleşik) yöntemleriyle elde edilen hisse senedi öngörü verileri kullanılarak optimize edilmiş portföylerin OV modeline göre daha yüksek performans göstereceği hipotezinin test edilmesi	ARFIMA ve FIGARCH Yöntemleri	Gerçek değerler	Markowitz Ortalama Varyans Portföy Optimizasyonu	-
Duqi vd.	2014	Bir modeli doğru tanımlayabilmek, yatırım portföylerinin getirilerini ve dalgalanmalarını doğru bir şekilde açıklayabilmek, bu modeli kullanarak Black-Litterman modelini dahil edecek şekilde bir dizi subjektif görüş geliştirebilmek.	EGARCH-M (Ortalamada Üstel GARCH) modeli	-	Black-Litterman Modeli	-
Gunasekaran ve Ramaswami	2014	İyi çeşitlendirilmiş bir portföy oluşturmak	ANFIS (Adaptif Nöro-Bulanık Çıkarım Sistemi)	-	Sermaye Varlıklarını Fiyatlandırma Modeli (CAPM)	Momentum Yatırım Portföyü ve Al - Sat Stratejisi
Hsu	2014	Tarihsel mali performansına dayalı belirli bir sanayi içinde kar yapmak için yüksek potansiyele sahip yatırımcıları görüntüleyen şirketlere yardımcı olmak	Genetik Programlama	-	Markowitz'in Ortalama-Varyans Modeli, Yapay Arı Kolonisi	-
Zhou vd.	2014	Bağımlı faktör yapıları ve gizli eşik yoluyla seyrek, kıt modeller uyararak dinamik faktör modellerinin öngörü performanslarını artırmak	Bayesci Markov Zinciri Monte Carlo Hesaplama Yöntemi	-	Markowitz Portföy Optimizasyonu	-
Gülten ve Ruszczyński	2015	Günlük hisse senedi portföy optimizasyonu için bir dizi risk modelleme ve optimizasyon tekniklerinin yararlılığını değerlendirmek	En Küçük Kareler Yöntemi	-	Senaryo Ağaç Oluşturma Yöntemleri	-

Çizelge 1.1. Tahminleme yöntemlerinden yararlanılarak yapılan Portföy Optimizasyonu çalışmaları (devamı).

Yazar	Yıl	Amaç	Tahmin Yöntemi	Karşılaştırılan Tahmin Yöntemi	Optimizasyon Yöntemi	Karşılaştırılan Optimizasyon Yöntemi
Luo vd.	2015	Üç model kullanılarak seçilen optimum portföy performanslarını araştırmak ve karşılaştırmak	Ortogonal GARCH (OGARCH) Modeli	Markov Switching Modeli ve Üstel Ağırlıklı Hareketli Ortalama (EWMA) Modeli	Ortalama-Varyans Modeli	-
Mendes vd.	2015	Verilen miktardaki varlıklar için uygun bir portföy bulma yeteneğine sahip optimum istenilen bir algoritma önermek	ARMA-GARCH Modeli	-	Bilgisayar Destekli Arzu Edilirlik Ayarlama Yöntemi	
Shao vd.	2015	Küresel hisse senetlerinden gelen uzlaşma geçici kazanç tahmini (CTEF) verilerine ortalama-ETL portföy optimizasyonu uygulamak	ARMA-GARCH Modeli (Oto regresif Hareketli Ortalama (ARMA), Genelleştirilmiş Oto regresif Koşullu Varyans (GARCH))	-	Ortalama Beklenenden Kuyruk Kaybı (ETL) Portföy Optimizasyonu	-
Fernandes vd.	2016	Uygulamada kullanımına yönelik sağlam portföy optimizasyonuna yeni bir bakış açısı sağlamak	Karışık Sinyaller Modeli (Basit Hareketli Ortalama ve Üstel Hareketli Ortalama)	-	Sağlam Adaptif Portföy Optimizasyonu Modeli (Doğrusal Programlama)	Al-Sat Stratejileri ve Eşit Ağırlıklı Strateji
Fulga	2016	Karar vericinin risk ve zarar kaçınma düzeyine göre modifiye edilmiş zarar dağıtımı ile tanımlanmış bir kantil tabanlı risk ölçümü önermek	Filtrelenmiş Tarihsel Simülasyon Yöntemi	-	Ortalama - DCVaR Modeli	Ortalama-Varyans (MV) Modeli, Ortalama-CVaR(MC) Modeli

Çizelge 1.1. Tahminleme yöntemlerinden yararlanılarak yapılan Portföy Optimizasyonu çalışmaları (devamı).

Yazar	Yıl	Amaç	Tahmin Yöntemi	Karşılaştırılan Tahmin Yöntemi	Optimizasyon Yöntemi	Karşılaştırılan Optimizasyon Yöntemi
Mishra vd.	2016	Tahmine dayalı yeni bir Ortalama-Varyans (PBMV) modeli öne sunmak	FANN (Sezgisel Fonksiyonel Bağlantı Yapay Sinir Ağı)		SR-MOPSO (Kendini Düzenleyen Çok Amaçlı Parçacık Sürüsü Optimizasyonu) Algoritması (MOEA (Çok Amaçlı Evrimsel Algoritmalar))	SPEA2 (Dayanımlı Pareto Evrimsel Algoritma 2), NSGA-II (Baskın Olmayan Sıralama Genetik Algoritma-II)
Ranković vd.	2016	Gerçek portföy çerçevesinde mean-VaR portföy optimizasyonu uygulamak	GARCH Modeli	-	NSGA-II (Baskın Olmayan Sıralama Genetik Algoritma-II)	Doğrusal Programlama Optimizasyon Yaklaşımı

Steiner ve Wittkemper (1997), doğrusal olmayan bir dinamik sermaye piyasası modeli olan Düzenli Piyasalar Hipotezi çerçevesinde gömülü yapay sinir ağlarına dayalı bir portföy optimizasyonu modelini açıklamışlardır. Bu çalışmanın amacı, günlük ticarete dayalı bir portföy yapısı optimizasyonu için bir model tanımlamak ve geliştirmektir. Hisse senedi toplama kararları doğrusal olmayan bir sermaye piyasası modeli olan Düzenli Piyasalar Hipotezinden (CMH) türetilmiştir. Tahmin ve öngörü modüllerinin altında yatan uygulama, Yapay Sinir Ağlarına dayanmıştır. Sinir ağları, temel durumu ve belirli hisse senetlerinin oluşturduğu grup davranışının seviyesini tahmin etmek amacıyla getiri dağılımlarını tahmin etmede kullanılmıştır. Bu tahminlerin temelinde ilgili hisse senedi performansı tahmin edilmiş ve bu tahmin hisse senedi portföylerini yönetmek için kullanılmıştır. İkinci bir aşamada bu model, örnek dışı veri ile test edilmiştir.

Modellerinde öncelikle, Olasılıksal Sinir Ağları yardımıyla Düzenli Piyasalar Hipotezi parametreleri tarafından açıklanan hisse senedi dağılımını tahmin etmişlerdir. Daha sonra, her bir hisse senedinin günlük getirilerini tahmin etmek için genel bir regresyon sinir ağı kullanılmıştır. Bu bilgi hisse senedi sıralamasını hesaplamak ve belirli dört portföyü yönetmek için kullanılmıştır.

1991-1994 yılları arasından örnek dışı veri ile yapılan bir simülasyonda 8 adet en iyi sıraya sahip hisse senedi ile oluşturulan bir portföy piyasa portföyünden yaklaşık %25 daha yüksek bir yıllık getiri elde etmiş ve en kötü sıraya sahip 8 hisse senedinden oluşturulan portföy ise piyasa portföyü getiri oranından yaklaşık %25 daha düşük bir getiriye ulaşmıştır. Bahsedilen iki portföye dayalı bir finansal riskten korunma stratejisinin, piyasa portföyündeki bir Al ve Sat Stratejisi riskinin %41'ine sahip piyasa portföyünün hareketleri gözetilmeksizin yaklaşık %25 pozitif yıllık getiri sağlayacağı saptanmıştır. Bu çalışmanın hesaplama sonuçları, doğrusal olmayan bir dinamik model olarak Düzenli Piyasalar Hipotezinin, Alman borsası için geçerliliğini kanıtlamıştır.

Freitas vd. (2009), yaptıkları çalışmada kısa vadeli yatırım fırsatlarını yakalayabilen tahmine dayalı yeni bir portföy optimizasyonu modeli sunmuşlardır. Hisse senedi getirilerini tahmin etmek için sinir ağı tahminleyicilerini kullanmışlar, ortalama-varyans modeli ile aynı istatistiksel temellere sahip tahmin hatalarına dayanan bir risk ölçüsü üretmişlerdir. Hisse senetlerini Otoregresif Hareketli Referans Sinir Ağı (AR-MRNN) isimli yeni bir yöntem kullanarak tahmin etmişler ve AR-MRNN'yi yeni bir portföy optimizasyonu modeli olan Tahmin-Tabanlı Portföy Optimizasyonu modelinin uygulanmasında kullanmışlardır. Düşük ve

tamamlayıcı ikili hata profillerine sahip tahminleyicilerin seçimi sayesinde başarılı çeşitlendirme elde etmişlerdir.

Tahmine Dayalı Portföy Optimizasyonu modelinin performansını Ortalama-Varyans modeli ve IBOVESPA piyasa endeksi performansı ile karşılaştırmışlardır.

AR-MRNN her bir tahmin için, zaman serisi değerleri ve referans olarak kullanılan belirlenmiş bir geçmiş değer arasındaki farklara denk gelen regresyon değişkenlerini kullanır. AR-MRNN tahminleyicileri tarafından üretilen tahmin hatalarının bazı dağılım etkileri test edilmiş ve kullanılan hisse senetlerinin %92'sinin normal dağılıma sahip olduğu doğrulanmıştır.

Kendi modelleriyle gerçekleştirdikleri simülasyonlar benzer risk seviyelerinde ortalama-varyans modelinin %292 üzerinde getiriye ulaşmıştır. Ayrıca, tahminleyici portföyler IBOVESPA piyasa endeksinin %78 üzerinde getiriler elde ederek daha iyi bir piyasa endeksi takip yeteneği göstermişlerdir.

Hesaplama sonuçları göstermektedir ki, Tahmin-Tabanlı Portföy Optimizasyonu modeli tahminleyici fırsatları Ortalama-Varyans modelinin iki katından daha fazla açıklamaktadır. Tahmin-Tabanlı Portföy Optimizasyonu modeli aynı zaman periyodunda aynı hisse senetleri kullanırken daha düşük risklerle daha yüksek getiriler elde ettiği için Ortalama-Varyans modelinden ve Brezilya IBOVESPA piyasa endeksinden daha üstündür.

Gunasekaran ve Ramaswami (2014), hisse senedi portföy optimizasyonu için Adaptif Nöro-Bulanık Çıkarım Sistemi (ANFIS) ve Sermaye Varlıklarını Fiyatlandırma Modeli (CAPM) birleşiminin kullanımını öneren bir yaklaşımı göstermişlerdir. Etkili bir tahmin modeli oluşturmak üzere, BSE SENSEX tarihsel verisi ve bilinen teknik göstergeler ile hisse senedi fiyatı tahmini amacıyla kararlar almak için ANFIS kullanılmıştır. Çalışmaya, bir portföyün beklenen getiri ve riski arasındaki yatırım hareketlerini önermek için hisse senedi birleşimini bulabilen portföy optimizasyonu için CAPM dahil edilmiştir. ANFIS-CAPM yatırımcılara portföy stratejileri bulmakta belirleyici bir rol oynamıştır ve hisse senetlerinden oluşan bir birleşiminden en iyi portföyü meydana getirmiştir. Çalışmada önerilen model Momentum Yatırım Portföyü modeli ve AI-Sat Stratejisi modeli ile karşılaştırılmıştır.

Melez model, diğer modellere kıyasla yatırım değeri üzerinde önemli ölçüde daha yüksek getiri sağlamıştır. Hesaplama sonuçları, önerilen melez zeki sistem ANFIS-CAPM 'in, mevcut portföy modellerinden daha iyi performans elde ettiğini göstermiştir. Sonuçlara göre bir dizi teknik gösterge ile ANFIS aracılığıyla hisse senedi eğilimi tahmini portföy optimizasyonu

için kullanılan CAPM modelinin performansını önemli ölçüde geliştirmiştir. Çalışmadan çıkarılan sonuçlara göre, hisse senedi eğiliminin başarılı tahmini ile cazip karlar elde edilebileceği için hisse senedi tahmini ve portföy optimizasyonu karmaşık ve oldukça ilginç finans konularıdır. ANFIS-CAPM bağımsız, kendi kendine muhakeme edebilen ve yorumlanabilir olduğu için bu amaç doğrultusunda oldukça uygundur.

Mishra vd. (2016), kısıtlı portföy optimizasyonu problemini çözmek için geleneksel Markowitz Ortalama-Varyans modeline alternatif olarak tahmin tabanlı yeni bir Ortalama-Varyans Modeli (PBMV) ileri sürmüşlerdir. Markowitz Ortalama-Varyans modelinde beklenen gelecek getiri, doğru olmamakla birlikte geçmiş getirilerin ortalaması olarak alınır. Önerilen modelde öncelikle, düşük karmaşıklıkta Sezgisel Fonksiyonel Bağlantı Yapay Sinir Ağı (HFANN) modeli kullanılarak beklenen gelecek getiriler tahmin edilmiştir ve portföy optimizasyonu görevi Çok Amaçlı Evrimsel Algoritmalar (MOEAs) ile gerçekleştirilmiştir. Bu çalışmada, Kendini Düzenleyen Çok Amaçlı Parçacık Sürüsü Optimizasyonu (SR-MOPSO) ismindeki sürü zekası temelli çok amaçlı optimizasyon algoritması önerilmiş ve bu önemli problemi çözmek için çalıştırılmıştır. Diğer iki rakip çok amaçlı evrimsel algoritma uygulanarak Pareto çözümler elde edilmiş ve önerilen PBMV modelleri ve Markowitz Ortalama-Varyans modelleri altı performans ölçümü ve Pareto yüzeyleri kullanılarak karşılaştırılmıştır. Aynı zamanda bu çalışmada, algoritmaların performanslarının ikili karşılaştırmaları için Sign testi ve Wilcoxon rank testi kullanılarak parametrik olmayan istatistiksel analiz yürütülmüştür. Çalışmadan çıkarılan sonuç, önerilen PBMV modeli tabanlı yaklaşımın yeterli çeşitliliği koruyan ve aynı zamanda Markowitz modeline oldukça benzer daha iyi Pareto çözümler sağladığı olmuştur. Simülasyon sonuçlarından, PBMV temelli Kendini Düzenleyen Çok Amaçlı Parçacık Sürüsü Optimizasyonu (SR-MOPSO) algoritmasının diğer çok amaçlı evrimsel algoritmalar arasında en iyi Pareto çözümler sağladığı gözlemlenmiştir.

Portföy optimizasyon problemiyle, sermaye ve yatırım kavramının geçtiği her yerde karşılaşılmakta ve bu problemin daha başarılı çözümü için çok sayıda akademisyen ve yatırımcı çözüm yolları aramaktadır. Ancak üzerinde bu kadar çok çalışılmasına rağmen, bahsi geçen problemlerin hepsine birden çözüm getiren ideal bir yöntem hala bulunamamıştır. Bütün problemlere birden çözüm bulan tek bir model beklemek de pek anlamlı görülmemektedir (Pekkaya ve Albayrak, 2013).

Bu çalışmanın amacı, zeki tahminleme yöntemlerine göre Markowitz'in ortalama-varyans modelinin performansını analiz etmektir. Çalışmada BIST 30'da işlem gören 26 hisse senedine ait 2008-2014 yılları arasındaki aylık kapanış fiyatları değerleri kullanılmıştır.

Çalışmaya aylık kapanış değerlerinin betimsel istatistiklerinin oluşturulması ve normal dağılım testlerinin yapılmasıyla başlanmıştır. En iyi tahmin aracının bulunması için Yapay Sinir Ağları ve Zaman Serileri Analizi Yöntemleri karşılaştırılmıştır. İlk olarak, Yapay Sinir Ağlarının en iyi parametre değerleri ve tahminin yapılması gereken en uygun zaman diliminin bulunması amaçlanmıştır. İkinci aşamada, 2008-2013 yıllarına ait aylık kapanış fiyatı değerlerinden hareketle Basit Ortalama Yöntemi, Hareketli Ortalamalar Yöntemi, Üstel Düzeltme Yöntemi ve Trend Analizi Yöntemi kullanılarak 2014 yılına ait 12 aylık kapanış fiyatları tahmin edilip Yapay Sinir Ağı Sonuçları ile karşılaştırılmıştır. Sonuçlara göre en iyi tahmin değerlerini veren yöntemlerin Yapay Sinir Ağları ve Üstel Düzeltme yöntemleri olduğu tespit edilmiştir. Son olarak, Yapay Sinir Ağları, Üstel Düzeltme ve geçmiş gerçek veriler kullanılarak Markowitz 'in Ortalama-Varyans modeli aracılığıyla modeller kurulmuştur. Bu modellerin farklı beklenen getiri düzeylerindeki varyansları ile gerçek değerler ile yapılmış olan portföy optimizasyonu modelinin varyansları etkin sınır grafikleri çizilerek karşılaştırılmıştır. Modellere ait varyanslar ile gerçek verilere dayanarak oluşturulan modele ait varyanslar arasındaki mutlak hatalar üzerinde Anova Analizi ve Tamhane testi gerçekleştirilerek sonuçların doğruluğu istatistiksel olarak gösterilmiştir.

Bu tez çalışması giriş bölümü hariç altı ana bölümden oluşmaktadır. Giriş bölümünde kısaca portföy optimizasyonu tanıtılmış, geçmişte hisse senetlerinde tahminleme yapmış olan çalışmalar hakkında bilgi verilmiş, bu çalışmalardan Yapay Sinir Ağlarından faydalanılarak gerçekleştirilen çalışmalar detaylı olarak anlatılmış, tez çalışmasının amacı, genel yapısı ve bölümlerinin içeriği hakkında bilgi verilmiştir.

Çalışmanın ikinci bölümünde, Markowitz'in Ortalama-Varyans Modeli çatısı altında öncelikle portföy kuramı ve portföy optimizasyonu açıklanmış ve buna bağlı olarak portföy ile ilgili temel kavramlar verilmiştir. Daha sonra finansal varlıkların ve bu varlıkların bileşimlerinden oluşan portföyün getiri ve riskinin hesaplanması, Geleneksel Portföy Teorisi (GPT), Modern Portföy Teorisi (MPT) anlatılmıştır. Bölümde son olarak, eniyi portföyün nasıl olması gerektiği açıklanmıştır.

Üçüncü bölümde tahmin yöntemleri ele alınmıştır. Tahmin yöntemleri nitel ve nicel yöntemler olmak üzere iki bölümde incelenmiştir. Nicel yöntemlerden Zaman Serileri Analizi ve Yapay Zeka ve Sezgisel Algoritmalar detaylı bir şekilde anlatılmıştır.

Çalışmanın dördüncü bölümünde yapay sinir ağları genel olarak açıklanmış ve bu kapsamda Yapay Sinir Ağlarının tanımı, uygulama alanları, avantaj ve dezavantajları, biyolojik

sinir hücresinin yapısı, yapay sinir hücresinin yapısı, Yapay Sinir Ağlarının sınıflandırılması, Yapay Sinir Ağlarındaki öğrenme algoritmaları ve Yapay Sinir Ağları modellerinden bahsedilmiştir.

Beşinci bölümde, tahmin performansı ölçme teknikleri anlatılmıştır. Bu tekniklerden Hata Büyüklüğü Doğruluğu, Ortalama Hata (ME), Ortalama Kare Hata (MSE), Ortalama Kare Hataların Kökü (RMSE), Ortalama Mutlak Yüzde Hata (MAPE) ve Theil U İstatistiği'nin tanımları ve hesaplanma şekilleri açıklanmıştır.

Çalışmanın altıncı bölümünde ise BIST 30'da yer alan hisse senetleri kullanılarak veri analizinin gerçekleştirildiği, Yapay Sinir Ağları ve diğer tahmin yöntemleri ile kapanış fiyatları tahmininin yapıldığı, aynı zamanda optimum portföyün elde edildiği uygulama bölümü yer almaktadır.

2. MARKOWITZ'İN ORTALAMA-VARYANS MODELİ

2.1. Portföy Kuramı

Bireyler, aileler ve şirketler için para yatırımı sorunu ortaktır. Aileler genellikle tasarruflarını enflasyondan korumayı veya tasarruflarını riske atmadan ek bir para kazanmayı hedeflemektedirler. Şirketler makul bir riskle yüksek getiri fırsatları arayan daha karmaşık yatırım stratejileri ile karşı karşıya kalmaktadırlar. Finansal kuruluşlar herhangi bir yatırımcı adına para yatırır. Finansal piyasaların küreselleşmesi ve yeni yatırım araçlarının oluşturulması nedeniyle yıllar geçtikçe yatırım fırsatlarının sayısı önemli ölçüde artmıştır. Günümüzdeki temel yatırım araçları sınıfları, tahvil, hisse senetleri, yatırım fonları (sosyal sorumluluk fonları da dahil) ve türevleri, menkul kıymetleştirme süreçlerinden (örneğin aktifleştirilmiş menkul kıymetler) yaratılmış varlıkları içermektedir (Mansini vd., 2015).

Bir portföy, bir kurum ya da özel bir şahsın sahip olduğu bir yatırım koleksiyonudur. Portföyler, yatırım stratejisinin bir parçası olarak çeşitlendirme amacıyla oluşturulur ve düzenlenir. Çeşitlendirme kavramı çok güçlü ve sezgiseldir. Bir portföye bir takım varlıkların dahil edilmesi, performansı azaltmaksızın portföy riskini önemli ölçüde azaltabilir. Bu nedenle, portföy çeşitlendirilmesi riski, yatırım yönetiminin kilit bir unsurudur (Rachev vd., 2008).

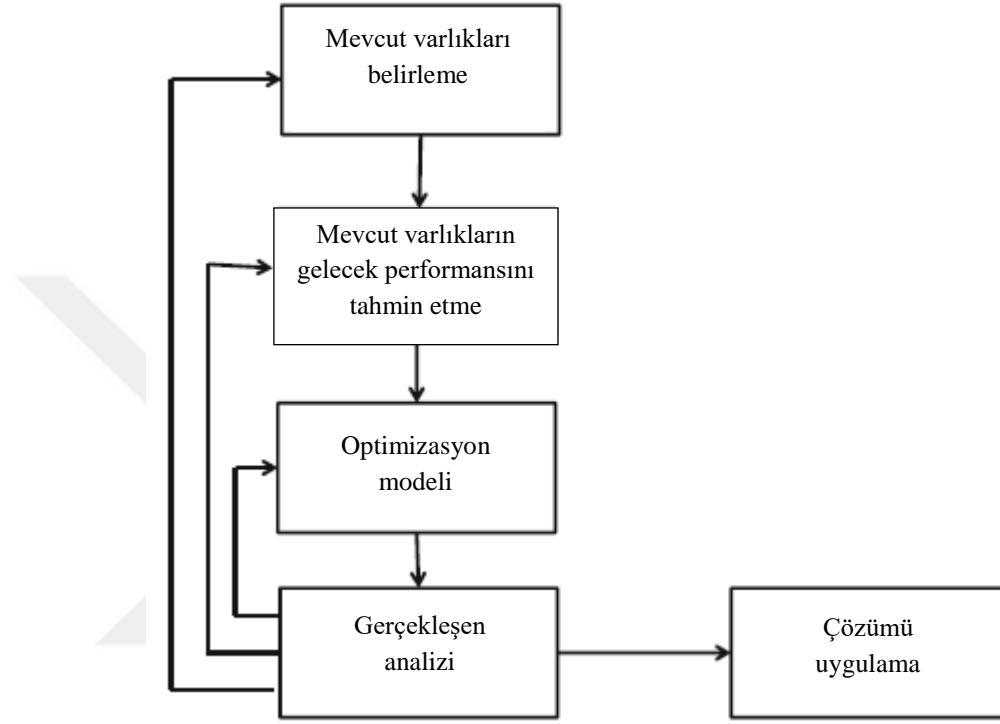
Portföy, riski azaltmak ve üstlenilen riske göre en yüksek getiriyi sağlamak amacı ile en az iki çeşit menkul kıymetten oluşan bir havuzdur. Yukarıdaki portföy tanımı menkul kıymetler açısından yapılmış bir tanımlama olup, bunu gayrimenkul gibi duran varlık yatırımlarını da içine alacak şekilde genişletmek mümkündür (Ercan ve Ban, 2008).

Bir başka tanıma göre portföy, ağırlıklı olarak hisse senedi, tahvil gibi menkul kıymetler ve türev ürünler gibi çeşitli menkul kıymetlerden oluşan, belirli bir şahıs ve grubun elinde bulunan finansal kıymetlerdir. Yatırım kavramı genel olarak sermaye ve/veya servet birikimini artırma amaçlı gerçekleştirilen her türlü faaliyet olarak ifade edilirken; portföy ise, bu servetin oluşturulma biçimidir (Civan, 2007).

2.2. Portföy Optimizasyonu

Optimizasyon, çerçevesini tanımlamak için zamanlamasının dikkatle düşünülmesi gereken bir konudur. Portföyün ilk kez oluşturulduğu ve varlıkların yalnızca satın alındığı bir an vardır. Bu ana, yatırım zamanı denilmektedir. Mevcut portföyün revize edildiği ve piyasa

değişikliklerine göre düzeltildiği müteakip anlar olabilir. Bu durumda, varlıklar satın alınabilir veya satılabilir. Bu ayarlamalar, sabit veya değişken zaman aralıklarında yapılır ve ek işlem maliyetleri getirmelerine rağmen uygulanabilirler (Mansini vd., 2015).



Şekil 2.1. Portföy Optimizasyonu süreci (Mansini vd., 2015).

Yatırımcının portföyünün değişmeden kalacağı dönemi göz önünde bulundurulacaktır. Bu süre genellikle aylar veya yıllar mertebesinde, nispeten kısa veya çok uzun olabilir. Yatırımcı, bu dönemin sonundaki getiri ile ilgilenmektedir. Varlıkların gelecekteki performansı ile ilgili beklentilerin, hedef zaman olarak adlandırılan anda gerçekleşmesi beklenir. Bir portföyün yatırım süresinde oluşturulduğu ve hedef zamana kadar tutulduğu stratejiye alım ve satım stratejisi denir (Mansini vd., 2015).

Bilimsel bir yaklaşımla portföy oluşturma süreci, şu evrelerle tanımlanabilir (bakınız Şekil 2.1) (Mansini vd., 2015):

- 1.Mevcut varlıklar kümesinin belirlenmesi,
- 2.Mevcut varlıkların hedeflenen zamandaki performansının tahmin edilmesi için bilgi toplanması, inançlar, yöntemler,
- 3.Bir önceki aşamada elde edilen tahminlere dayanarak, portföy üreten bir modelin seçimi,

4. Modelin gerçekleşen (ex-post) analizi ve önceki aşamalardan birine olası geri bildirim yoluyla değerlendirmesi,

5. Portföyün uygulanması.

2.3. Portföy İle İlgili Temel Kavramlar

Etkili bir portföy, belirli bir risk seviyesinde beklenen en yüksek getiriyi sağlayan veya belirli bir beklenen getiri için en düşük risk olan portföydür (Fabozzi ve Markowitz, 2011).

Etkin bir portföy oluşturmak için, yatırımcı, riski ölçebilmeli ve gerekli girdileri sağlamalıdır. İhtiyaç duyulan üç temel girdi vardır; gelecekteki beklenen getiri (veya sadece beklenen getiri), varlık getirilerinin varyansı ve varlık getirilerinin korelasyonudur (veya kovaryans) (Fabozzi ve Markowitz, 2011).

Portföy optimizasyonu modellerine geçmeden önce bu modellerde kullanılacak olan temel kavramlar üzerinde durmak yerinde olacaktır. Bu kavramlar dönemlik getiri, ortalama getiri, sapma ölçütleri, kovaryans, korelasyon katsayısı ve finansal varlıklardan muhtelif adetlerde alınarak oluşturulan portföylerin beklenen getiri-varyans ölçümleridir.

2.3.1. Dönemlik getiri

t kesikli noktalar dizisi iken, P_t 'yi finansal bir varlığın fiyatlarının bir zaman serisi olarak düşünülün. Bir varlığın $t - 1$ ve t dönemleri arasındaki *basit net getirisi*, fiyatının yüzdesel değişimi olarak tanımlanır (Fabozzi vd., 2007):

$$R_{it} = \frac{P_{it} - P_{i,t-1}}{P_{i,t-1}} = \frac{P_{it}}{P_{i,t-1}} - 1 \quad (2.1)$$

burada,

R_{it} = i hisse senedinin t dönemindeki getiri oranı,

P_{it} = i hisse senedinin t dönemindeki kapanış fiyatı.

2.3.2. Ortalama getiri

Ortalama getiri tahmini için farklı senaryolardaki getirilerin ve bu senaryoların olasılıklarının bilinmesi gerekir (Podding vd., 2005; Unger'den, (2015)):

$$\mu_i = \sum_{t=1}^T R_{it} / T \quad (2.2)$$

burada,

μ_i : i varlığının ortalama getirisi

T = toplam dönem sayısı

2.3.3. Sapma ölçütleri (varyans ve standart sapma (risk))

Standart sapma, bir yatırımın performans değişkenliğini ölçen en popüler yöntemdir. Bu istatistiksel ölçü, bir yatırım ürününün belirli bir zaman zarfında ortalama getirisini hesaplamak ve daha sonra ortalamanın tipik (standart) farkını (sapmasını) hesaplamak üzere tasarlanmıştır. Sonuç olarak, standart sapmayı bir yatırım ürününün tarihsel geri dönüş dağılımının bir ölçüsü olarak düşünebiliriz (Travers, 2004). Varyans ise standart sapmanın karesidir.

Her bir getiri eşit derecede muhtemel olduğunda, i . varlığın getirisinin varyansı için formül şu şekildedir (Ulucan, 2004):

$$\text{var}(R_i) = \sigma^2 = \sum_{t=1}^T (R_{it} - \mu_i)^2 / T \quad (2.3)$$

2.3.4. Kovaryans

Menkul kıymetlerin tek tek risklerini varyans veya standart sapmayla ölçmek mümkündür. Ancak, iki veya daha çok menkul kıymet yani bir portföy söz konusu olduğunda risk, kovaryansla ifade edilir (Markowitz, 1952).

Kovaryansın pozitif olması, iki menkul kıymetin aynı anda aynı yönde hareket ettiğini göstermektedir. Bu durumda hisse senetlerinden birisinin getirisi artarken diğerinin de artmakta, birisi azaltılırken diğerininki de azalmaktadır. Negatif kovaryans, iki menkul kıymetin aynı anda ters yönde hareket ettiğini gösterir. Negatif kovaryans, hisse senetlerinden herhangi birinin getirisi arttığında, diğer hisse senedinin getirisinin düştüğünü göstermektedir (Dağlı, 2004).

İki menkul kıymetin getirilerinin kovaryansı, şu eşitlikle hesaplanmaktadır:

$$\text{Cov}(R_i, R_j) = \sigma_{R_i R_j} = \frac{1}{T} \sum_{t=1}^T (R_{it} - \mu_i) \cdot (R_{jt} - \mu_j) \quad (2.4)$$

Kovaryans değeri 0'dan küçük olduğu durumlarda menkul kıymet getirileri arasında ters yönlü bir ilişki, 0'dan büyük olduğu durumlarda ise, aynı yönlü ilişki söz konusudur.

Kovaryans değeri 0'a yaklaştıkça ilişkinin derecesi azalırken, $-\infty$ ve $+\infty$ 'a yaklaştıkça ilişkinin derecesi artmaktadır.

Kovaryans iki rassal değişken arasındaki ilişkinin miktarının yararlı bir ölçüsüdür. Ancak kovaryansın hesaplanmasında iki önemli sakıncayla karşılaşmaktadır. Bu sakıncalardan birincisi kovaryansın uç sınırlarının olmamasıdır ($-\infty$ ile $+\infty$ arasında her değeri alabilir). İkincisi ise kovaryansın sayısal değeri tesadüfi değişkenleri ölçmek için kullanılan birimlerin sayısına dayanmasıdır. Örneğin, yükseklik ve ağırlık arasındaki kovaryansın sayısal değeri değişkenlerin inç ve pound veya santimetre ve kilo olarak ölçülmelerine bağlı olarak değişir. Bu sakıncalardan dolayı menkul kıymetler arasındaki ilişkinin olup olmadığı korelasyon katsayısıyla ölçülmelidir (Kolb ve Rodrigues, 1992).

2.4. Portföy Teorileri

2.4.1. Geleneksel Portföy Teorisi

Geleneksel portföy yaklaşımının amacı, yatırımcının sağlayacağı faydayı maksimize etmek ve riski dağıtmaktır. Bu doğrultuda birden fazla varlığı bir araya getirerek yeni bir finansal varlık (portföy) oluşturmak mümkündür. Geleneksel portföy yaklaşımında yatırımcıların, gelecekteki menkul kıymet getirilerini ve bu getirilere göre ortaya çıkabilecek riskleri tahmin etmesi gerekmektedir. Portföy oluşturmanın temel amacı riskin dağıtılmasıdır. Geleneksel portföy yaklaşımı, bu görüşten hareketle, portföy içerisindeki menkul kıymet sayısının artırılması ilkesine dayanmaktadır (Ceylan ve Korkmaz, 1998; Karan, 2001; İskenderoğlu ve Karadeniz'den, (2011)).

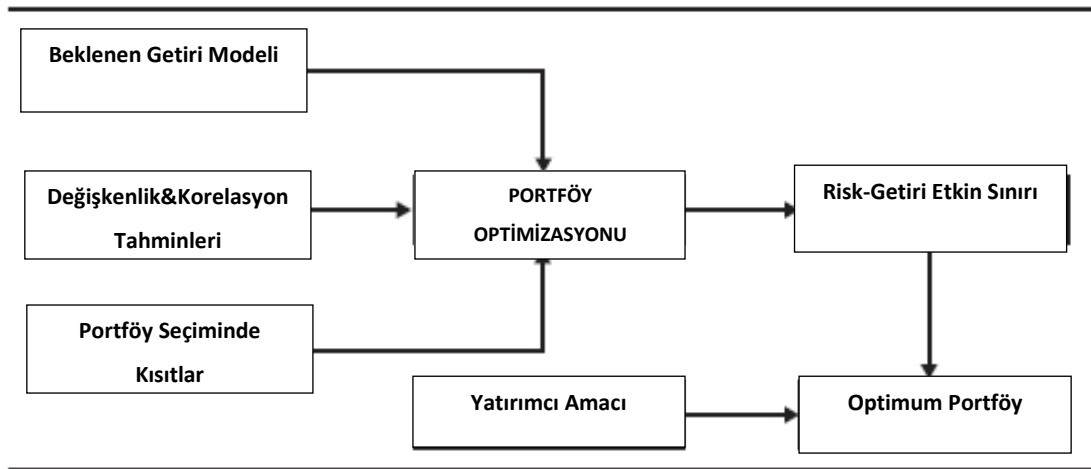
2.4.2. Modern Portföy Teorisi (MPT)

Modern portföy teorisi, modelleme çerçevesi olarak kullanılır çünkü özel sermaye (PE) fonları, kamu sermayesindeki farklılıklarına rağmen (Wright ve Robbie 1998), yatırım fonlarına benzer birçok riskli varlığın portföyüdür. Sharpe (1964), Sermaye Varlıkları Fiyatlama Modelinin ve bu nedenle modern portföy teorisinin tüm sermaye varlıklarına uygulanacağını öne sürmüştür. Modern portföy teorisi ilk olarak Markowitz (1952, 1959) tarafından tanıtılmıştır ve daha sonra Sharpe (1964) ve Lintner (1965) tarafından Sermaye Varlıkları Fiyatlama Modeli geliştirilmiştir. Markowitz (1999), risklerin birbiriyle ilişkilendirildiği zaman çeşitlendirmenin etkilerini kapsayan yeterli bir yatırım teorisi sağlamayı amaçlamıştır (Lossen, 2007).

MPT, yatırım yöneticilerinin kararlarını ve faaliyet göstermeleri gereken çeşitli kurum gerekliliklerini göz önüne alarak (örneğin, ciro ya da elde tutma kısıtlamaları) "eni" portföyü seçmek için bir yatırımcı topluluğuna bir yöntembilim sağlamaktadır (Corner ve Mayes, 1983).

Modern portföy teorisi (MPT), çeşitli varlıkların oranlarını dikkatle seçerek belirli bir portföy riski miktarı için portföyün beklenen getirisini maksimize etmeye veya belirli bir beklenen getiri seviyesi için riski en aza indirmeye çalışan bir yatırım teorisidir. MPT, finans sektöründe pratikte yaygın olarak kullanılmasına rağmen, son yıllarda MPT'nin temel varsayımları davranışsal ekonomi gibi alanlar tarafından büyük oranda tepki almıştır (Xidonas vd., 2012).

Şekil 2.2'de, modern portföy teorisi açısından yatırım süreci gösterilmektedir. Bu süreç genellikle ortalama varyans optimizasyonu veya portföy seçimi teorisi denir. Sürecin girdileri, çeşitli portföy kısıtları ile tüm varlıkların beklenen getirileri, volatiliteleri ve korelasyonları ile ilgili tahminlerdir. Örneğin, kısıtlar herhangi bir varlığın kısa sürede satılmasına izin verilmemesi kadar basit veya varlıkların yalnızca yuvarlak lotlarda işlem görmesinin sınırlandırılması kadar karmaşık olabilir. Ardından, etkin sınır oluşturmak üzere bir dizi optimizasyon problemini çözmek için bir optimizasyon yazılımı paketi kullanılır. Portföyün karmaşıklığına bağlı olarak, optimizasyonlar bir elektronik tablo veya daha özelleştirilmiş optimizasyon yazılımı ile çözülebilir. Etkin sınır hesaplandıktan sonra, çeşitli risk türlerinden kaçınma derecesi gibi yatırımcının hedeflerine bağlı optimal bir portföy seçilir (Fabozzi vd., 2007).



Şekil 2.2. MPT yatırım süreci (Fabozzi vd., 2002: Fabozzi vd.'den (2007)).

Markowitz (Ortalama-Varyans) Modeli

Portföy optimizasyonunun matematiksel problemi birçok yönden formüle edilebilir ancak asıl problemler şu şekilde özetlenebilir (Gupta vd., 2014):

1. Belirli bir beklenen getiri için riski en aza indirmek,
2. Belirlenen bir risk için beklenen getiriyi en üst düzeye çıkarmak,
3. Belirli bir riskten kaçınma faktörü kullanarak riski en aza indirmek ve beklenen getiriyi en üst düzeye çıkarmak,
4. Beklenen getiriden bağımsız olarak riski en aza indirmek,
5. Riskten bağımsız olarak beklenen getiriyi en üst düzeye çıkarmak.

MPT çerçevesi, yatırımcılar ve pazarlar hakkında birçok varsayımlarda bulunur. Normal dağılımların model getirilerine uygulanması gibi bazıları denklemlerde açıktır. Diğerleri, vergi ve işlem ücretlerinin ihlali gibi örtülüdür. Bu varsayımlardan hiçbiri tamamen doğru değildir ve her biri MPT ile bir dereceye kadar uyuşur. Temel MPT varsayımları aşağıdaki gibidir (Xidonas vd., 2012).

1. Yatırımcılar, yukarıda açıklanan optimizasyon problemi ile ilgilenmektedirler (belirli bir varyans için ortalamayı en yüksek düzeye getirmek).
2. Varlık getirileri (ortaklaşa) normal dağılıma sahip rassal değişkenlerdir.
3. Varlıklar arasındaki korelasyonlar değişmez ve sonsuza kadar sabittir.
4. Tüm yatırımcılar, ekonomik faydayı maksimize etmeyi amaçlamaktadır (başka bir deyişle, diğer hususlara bakılmaksızın, mümkün olduğunca fazla para kazanmayı hedeflerler).
5. Tüm yatırımcılar rasyoneldir ve riskten kaçınırlar.
6. Tüm yatırımcılar aynı anda aynı bilgilere erişebilirler.
7. Yatırımcılar olası getirileri doğru bir şekilde kavrar; yani, yatırımcıların olasılık inançları, gerçek getiri dağılımına uymaktadır.
8. Vergi veya işlem maliyeti yoktur. Gerçek finansal ürünler, hem vergilere, hem de işlem maliyetlerine (örneğin komisyoncu ücretlerine) tabidir ve bunları dikkate almak eniyi portföyün kompozisyonunu değiştirir.
9. Tüm yatırımcılar fiyat alıcısıdır; yani, eylemleri fiyatları etkilemez.
10. Herhangi bir yatırımcı, riskten arındırılmış faiz oranı ile sınırsız miktarda kredi alabilir ve borcu ödeyebilir.
11. Bütün menkul kıymetler, herhangi bir boyuta sahip parsellere bölünebilir.

Finansal yatırımların yönetilmesinin temelleri, Harry Markowitz tarafından ortalama varyans analizi çerçevesinde bir portföy optimizasyon formülü oluşturulması yoluyla atılmıştır. İstatistik açısından, yatırımlar, beklenen uzun vadeli getiri oranlarına ve beklenen kısa vadeli volatiliteye göre tanımlanmaktadır. Bu formülasyon, tüm varlıklara karşı tüm yatırımın çeşitlendirilmesi kavramını desteklemektedir. Teori, yukarıda bahsedilen varsayımlar çerçevesinde, belirli bir beklenen portföy getirisi için portföyün varyansının en aza indirgenmesine odaklanmaktadır. Genel olarak, ortalama-varyans değişimi, yatırımcının almak istediği risk seviyeleri yükseldikçe elde edeceği getirinin artacağını belirtir. Bu, risk seviyeleri ile beklenen getiriler arasında doğrusal bir ilişki olduğunu vurgular (Dangi, 2012).

Markowitz modeli, hedeflenen beklenen getiri düzeyini karşılayacak minimum varyanslı (minimum riskli) portföyü bulmaya çalışır. Modelde amaç fonksiyonu enküçüklenecek portföy varyansıdır ve Denklem 2.5'te verilmektedir (Ulucan, 2004).

$$Enk \sum_{i=1}^N \sum_{j=1}^N x_i x_j \sigma_{ij} \quad (2.5)$$

Bu matematiksel ifadede,

N : mevcut varlık sayısını,

σ_{ij} : i ve j varlıkları arasındaki kovaryans değerini ($i = 1, \dots, N$), ($j = 1, \dots, N$),

x_i : i. varlığın portföy içerisindeki oranını gösteren karar değişkenlerini

göstermek için kullanılmıştır.

Standart Markowitz modelinde iki temel kısıt vardır. Bunlardan birincisi, hedeflenen beklenen getiri düzeyinin karşılanmasını sağlayacak Denklem 2.6'daki matematiksel ifadedir (Ulucan, 2004).

$$\sum_{i=1}^N x_i \mu_i = R \quad (2.6)$$

burada,

μ_i : i varlığının beklenen getirisini ($i = 1, \dots, N$),

R : hedeflenen beklenen getiri düzeyini

göstermek amacıyla kullanılmıştır. Modeldeki ikinci temel kısıt ise, portföyde bulunan varlıkların ağırlıkları toplamının 1 olmasını sağlayan Denklem 2.7'deki ifadedir (Ulucan, 2004).

$$\sum_{i=1}^N x_i = 1 \quad (2.7)$$

Karar değişkenlerinin negatif olmama kısıtı da eklendiğinde Denklem 2.8'deki genel model elde edilir (Ulucan, 2004).

$$Enk \quad \sum_{i=1}^N \sum_{j=1}^N x_i x_j \sigma_{ij} \quad (2.8)$$

s.t.

$$\sum_{i=1}^N x_i \mu_i \geq R$$

$$\sum_{i=1}^N x_i = 1$$

$$0 \leq x_i \leq 1, i = 1, \dots, N$$

2.5. Portföyün Getirisi ve Riski

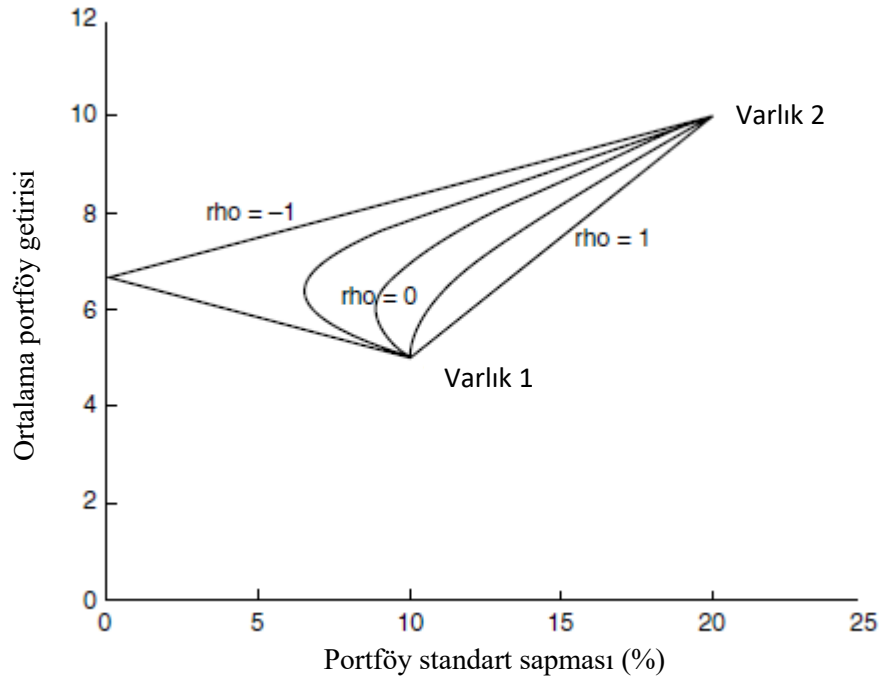
2.5.1. Risk ve beklenen getiri ilişkisi

Belirli bir fona veya belirli bir yatırım yöneticisi/ekibine yatırım yaptığımızda, yatırımın ömrü boyunca bekleyeceğimiz getiri konusunda da varsayımlar yaparız. Risk, getiri beklentilerimiz veya varsayımlarımızla birlikte gelen belirsizliktir. Farklı varlık sınıflarının farklı getiri ve risk beklentileri vardır. Örneğin uzun vadede küçük sermayeli şirket hisselerinin büyük sermayeli şirket hisselerine göre daha riskli olduğu (kar dalgalanmasına bağlı olarak) ortaya konmuştur. Sonuç olarak daha yüksek risk seviyelerinden ötürü küçük sermayeli şirketlere yapılan yatırımlardan büyüklere göre daha fazla kar beklenir. Genel bir kurala göre, beklenen risk ne kadar yüksekse, beklenen getirinin o kadar yüksek olması gerekir. Tam olarak aynı getiri beklentilerine sahip ancak farklı risk varsayımları olan iki yatırım arasında bir seçim göz önüne alındığında, sağduyumuz, daha düşük risk seviyesine sahip ürünü seçmemiz gerektiğini belirtir (Travers, 2004).

Beklenen getirileri, varyansları veya standart sapmaları ve korelasyonların varlıklar evreni için tahmin ettiğimizi varsayalım. μ , varlık portföyünün beklenen getirisi, μ_p , her bir varlığın portföy ağırlıklı beklenen getirisidir. Bir P varlık portföyünün varyansı σ_p^2 , portföy ağırlıklarına, portföydeki varlıkların varyansına, varlık çiftleri arasındaki korelasyona ρ (rho) bağlıdır. Standart sapma σ_p , varyansın kareköküdür ve varlık riskini tanımlamak için yararlı bir alternatiftir. Standart sapmanın varyansa tercih edilmesinin bir nedeni, ortalamanın getiri biriminde olmasıdır (Michaud ve Michaud, 2008).

Şekil 2.3, iki varlıktan oluşan bir portföy için ortalama ve standart sapmayı göstermektedir. Portföydeki beklenen getiri ve riskin bazı temel özelliklerini göstermektedir. Varlık 1'in beklenen getirisi % 5 ve riski % 10, Varlık 2'nin beklenen getirisi % 10 ve risk % 20'dir. Beş eğri, iki varlığı birbirine bağlar ve varlık 1'in sermayesinin % 100'ünden Varlık 2'nin sermayesinin % 100'üne kadar değişen, portföylerin risk ve beklenen getirisini gösterir. Beş eğri ile (sağdan sola) ilişkili varlık korelasyonları 1.0, 0.5, 0, -0.5 ve -1.0'dır (Michaud ve Michaud, 2008).

Beş eğri, korelasyonların ve portföy ağırlıklarının portföy riskini ve beklenen getiriyi nasıl etkilediğini göstermektedir. Şekilde en sağdaki eğride olduğu gibi korelasyon 1 olduğunda, portföy riski ve beklenen getiri, iki varlığın risk ve getirisinin ağırlıklı ortalamasıdır. Bu durum çeşitlendirmeye fayda sağlamayacaktır. Diğer tüm durumlarda, varlıkların kendileri dışında, portföy riski varlıkların riskinin ağırlıklı ortalamasının altında bulunur. Çoğu durumda, varlık ilişkileri 1'den düşüktür. ABD hisse senedi korelasyonları genellikle 0,3 ila 0,5 aralığındadır. Korelasyon seviyesi azaldığında mevcut risk azaltma miktarı artar. İki varlık arasındaki -1 korelasyonunda (aşırı sol eğri), portföy riskini ortadan kaldırmak mümkündür (Michaud ve Michaud, 2008).



Şekil 2.3. Portföy risk ve getirisi: iki varlıklı durum (Michaud ve Michaud, 2008).

2.5.2. n varlıktan oluşan portföyün beklenen getirisi ve riski

İki yatırımın normal dağılıma sahip olduğu (simetrik) etkin sermaye piyasalarında, rasyonel (riskten kaçınan), çeşitlendirme vasıtasıyla hizmet tercihlerini en üst düzeye çıkartabilecek optimal bir portföye ihtiyaç duyan yatırımcılar ve şirketler yukarıda anlatılmıştır. Yatırımların herhangi bir bileşimi, normal dağılımı tanımlayan durağan parametreler bireysel getirilerin kovaryansı ile ilgili beklenen getiri ve standart sapma (risk) arasında bir ödünleşim (trade-off) oluşturur (Hill, 2010).

Verimli çeşitlendirilmiş portföyler, belirli bir risk seviyesi için getiriye en üst düzeye çıkaran veya farklı korelasyon katsayılarında belirli bir getiri seviyesi için riski en aza indiren portföylerdir (Hill, 2010).

Bununla birlikte, çoğu yatırımcı veya şirket ve finansal yöneticiler çok sayıda yatırımdan sorumlu olabilirler. Bu nedenle, analizimizi, ikiden fazla bileşeni olan portföylere yaymamız önemlidir (Hill, 2010).

n ' nin varlıkların sayısını ve x_i ' nin her birine yatırım yapılan fonların oranını temsil ettiği çok varlıklı bir portföy için (Hill, 2010):

$$\sum_{i=1}^n x_i = 1, x_i \geq 0, \forall i \quad (2.9)$$

Portföy getirisini ve varyansını aşağıdaki gibi tanımlayabiliriz.

$$R(P) = \sum_{i=1}^n x_i R_i \quad (2.10)$$

$$\sigma_P^2 = \sum_{i=1}^n x_i^2 \sigma_i^2 + \sum_{i \neq j} x_i x_j \sigma_{ij} \quad (2.11)$$

2.6. Optimum Portföy

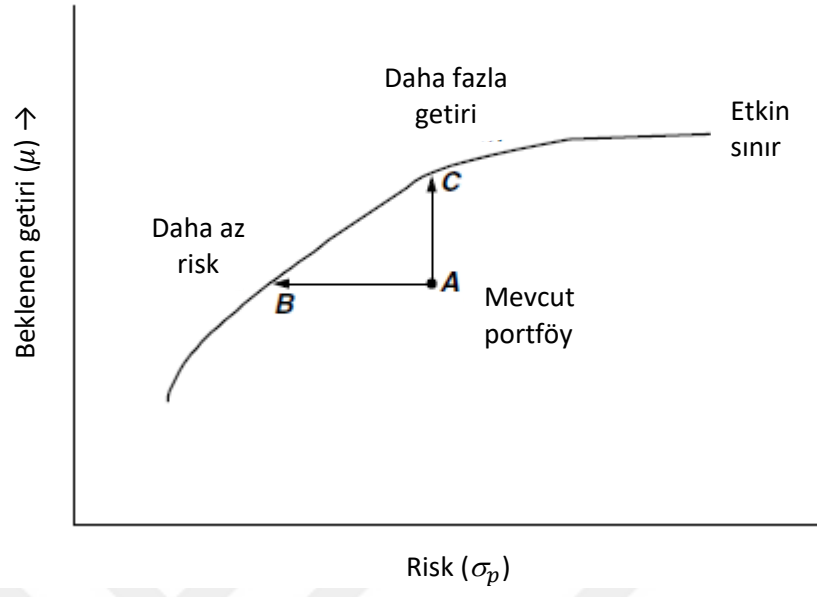
Uygun (feasible) bir portföy, belirlenen kısıtları sağlayandır. Ortalama varyans etkin (efficient) portföy ise bu uygun portföylerden, belirlenen (veya daha düşük) varyans değeri için enbüyük beklenen getiriye sağlayan ya da belirlenen (veya daha büyük) beklenen getiri için enküçük varyansı elde eden portföydür. Beklenen değer ve varyans, etkin ortalama-varyans (OV) birleşimi diye isimlendirilen etkin portföy tarafından oluşturulur. İşte tüm etkin OV birleşimlerinin oluşturduğu kümeye de “etkin sınır” (efficient frontier) denir ve portföy yöneticisinin amacı “etkin sınır üzerindeki noktaları belirlemektir” (Jakobs vd., 2005).

n sayıda menkul kıymet bulunan bir portföyde, menkul kıymetlere değişik ağırlıklar verilerek sınırsız sayıda portföy oluşturulabilir. Bu nedenle yatırımcı, ya beklenen bir getiri oranı düzeyinde varyansı (ya da riski) enküçükleyecek bir portföyü seçecek ya da belirli bir varyans değerinde getirisi en yüksek olan portföyü seçecektir. Yani yatırımcılar portföy oluştururken hem beklenen getiriyi hem de riski göz önüne alır. Portföydeki her bir menkul kıymetin payı ise matematiksel olarak karesel atama ile hesaplanır (Gökgöz, 2006).

Etkin Sınır (Efficient Frontier)

Markowitz (1959) ortalama-varyans etkinliği, modern finansın klasik paradigmasıdır ve sermayeyi riskli varlıklara verimli bir şekilde dağıtmak için kullanır. Beklenen getiri, standart sapma veya varyans tahminleri ve bir varlıklar kümesi için getiri korelasyonu göz önüne alındığında, OV verimliliği, yatırımcıya optimal sermaye dağıtımı için formül sunmaktadır. Markowitz etkin sınırı (Şekil 2.4), diğer tüm portföylerin belirli bir risk seviyesinde beklenen getirilerinin az olması veya belirli bir beklenen getiri seviyesinin eşdeğerliği açısından daha fazla risk oluşturmaları anlamında etkin olan tüm portföyleri temsil eder. Bu çerçevede, getirinin varyansı veya standart sapması portföy riskini tanımlar. OV verimliliği sadece menkul kıymetlerin riskini ve getirisini değil, aynı zamanda karşılıklı ilişkilerini de göz önüne alır (Michaud ve Michaud, 2008).

Şekil 2.4'te, Portföy A, belirli bir beklenen getiri ve standart sapma ile yatırımcının mevcut portföyü olarak kabul edilmektedir. Portföy B, Portföy A'nın beklenen getirisinin aynı seviyesinde daha az riske sahip etkili portföydür. Portföy C, Portföy A ile aynı risk seviyesinde daha fazla beklenen getiriye sahip etkin portföydür. Etkin sınır, tüm etkin portföylerin ortalama ve standart sapmasını tanımlar (Michaud ve Michaud, 2008).



Şekil 2.4. Ortalama-varyans portföy verimliliği (Michaud ve Michaud, 2008).

3. TAHMİN YÖNTEMLERİ

Tahmin yöntemi, gelecek zaman dilimindeki bir değerle tahmin edilmesini, nokta tahminini sağlayan bir algoritmadır (Hyndman, 2008). Tahmin, çoğu operasyonel faaliyetin ön şartıdır. Beklenen etkinlik düzeyini geleceği tahmin etmeden planlamak mümkün değildir (Lewis, 1997).

Tahmin yöntemlerini sınıflandırmanın veya kategorize etme yollarından biri, Çizelge 3.1' de gösterildiği gibi, analiz edilen talep verileriyle ilişkili zaman dilimi temelinde tahmin türünü tanımlamaktır (Lewis, 1997).

Çizelge 3.1. İlgili verilerin altında yatan zaman birimi temel alınarak tahmin türlerinin kategorize edilmesi (Lewis, 1997).

Tahmin çeşidi kategorisi	Analiz edilecek veri ile ilişkili zaman periyodu	Tahmin uygulaması örneği	Kullanılan tahminleme yöntemleri
Yakın-dönem	¼ saat -1 gün	Elektrik talep tahmini	Çeşitli
Kısa-dönem	1 hafta – 1 ay	Endüstri ve ticarete talep tahmini	Üstel ağırlıklı ortalamalar ve türevleri
Orta-dönem	1 ay – 1 yıl	Satışlar ve finansal tahminleme	Regresyon, eğri uydurma, zaman serileri analizi
Uzun-dönem	1 yıl – 10 yıl	Teknolojik tahminleme	DELPHI, beyin takımı vb.

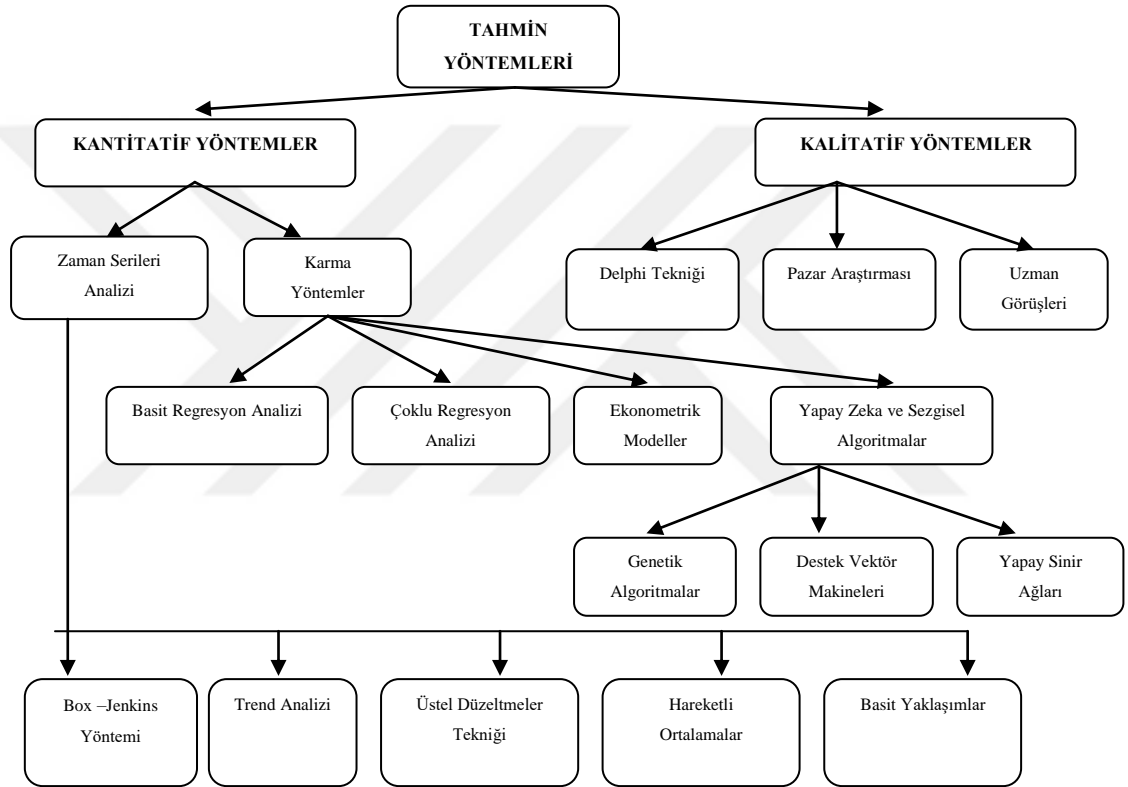
Tahmin sanatı, tahmindeki olası hata kaynaklarını en aza indirmek için mevcut bilginin bütünüyle en iyi şekilde kullanılmasını içerir. Tahmin yöntemi seçimi birçok faktöre bağlıdır. Bunlar (Lancaster ve Lomas, 1985);

- Planlama uzayı,
- Durum hakkında yapılan varsayımlar,
- Tarihsel verilerin doğası,
- Tahmin hazırlığının zaman ölçeği,

Tahmin hazırlığı maliyeti,
Pazarın yapısı

şeklinde sıralanabilir.

Şekil 3.1.'de Tahmin yöntemlerinin genel bir sınıflandırılması gösterilmektedir (<http://www.istanbul.edu.tr/muh/> : Karaatlı vd.'den (2012)).



Şekil 3.1. Tahmin yöntemleri.

Bir tahmin hazırlamak için kullanılacak tekniğin seçimi, her zaman doğruluk, zaman ölçeği ve maliyet arasında bir uzlaşdır. Tahmincinin görevi, belirli koşullar altında mümkün olan en üst düzeyde uzlaşmayı sağlamaktır. En iyi kullanımın mevcut bilgilerden yapıldığından emin olmak için, tahmin formülasyonunda kullanılan varsayımların hem tahminci hem de tahmini kullanan karar verici tarafından anlaşılması gerekir (Lancaster ve Lomas, 1985).

Varsayımların geçerliliği daima sorgulamaya açık olmalı ve tahminci, şartların açıklamasını değiştiren herhangi bir şeyin, tahmin tekniğinin seçiminin temelini yeniden değerlendirmesi gerektireceğini akılda tutmalıdır. Tahmin yönteminde değişiklik bekleniyorsa,

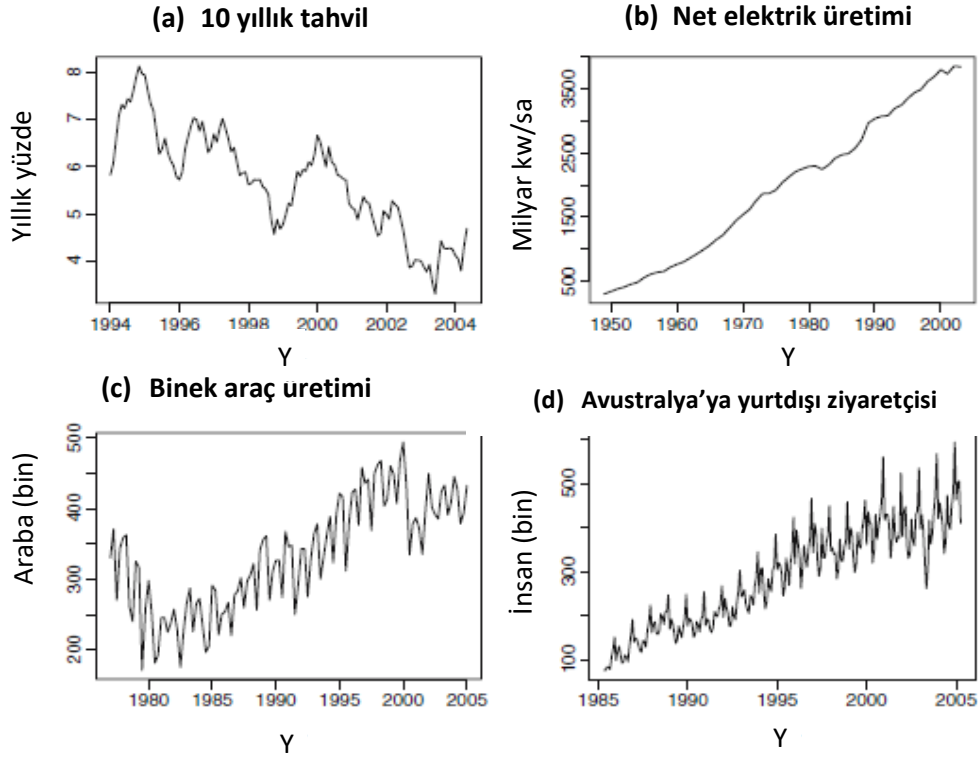
hatanın kabul edilebilir sınırları aşması durumunda yöntemde bir değişiklik başlatmak için tahmin hatasını izlemek gerekebilir (Lancaster ve Lomas, 1985).

3.1. Zaman Serileri Analizi

Bir zaman serisi, her biri belirli bir t zamanında kaydedilen x_t gözlemler kümesidir. Bir ayrık zaman serisi, gözlemlerin yapıldığı zamanların T_0 (başlangıç zamanı)'nın bir ayrık küme olduğu zaman serisidir. Gözlemlerin sabit zaman aralıklarında yapıldığı bir durum örnek olarak verilebilir. Sürekli zaman serileri, gözlemler bir süre boyunca sürekli olarak kaydedildiğinde elde edilir. $T_0=[0, 1]$ olduğunda kaydedilen sürekli veriler, sürekli zaman serileridir (Brockwell ve Davis, 1996).

Zaman serileri birçok farklı durumda oluşabilmektedir. Bunlardan bazıları; dakika bazında hisse senedi fiyatları, bir hava istasyonunda saatli hava sıcaklıkları, bir tıbbi kliniğe günlük gelenlerin sayısı, bir ürünün haftalık satışları, bir bölge için aylık işsizlik rakamları, bir ülkenin üç aylık dönem ithalatı ve bir şirketin yıllık cirosudur (Hyndman vd., 2008).

Bir zaman serisinin grafiği, yukarı veya aşağı doğru hareket (eğilim) veya tekrar eden (mevsimlik değişim) bir desen gibi gelecek değerleri tahmin etmek için kullanılacak desenler gösterir. Bu özellikleri gösteren dört zaman serisinin grafikleri Şekil 3.2'de gösterilmektedir (Hyndman vd., 2008).




Şekil 3.2. Ticari ve ekonomik veriler için tipik desenler gösteren dört zaman serisi (Hyndman vd., 2008).

Zaman serisi modeli oluşturulduktan sonra, bu yöntem yeterli bir tahmin yöntemi kullanılarak gelecek değerlerin tahmin edilmesinde kullanılabilir. Bir zaman serisinin gelecek değerlerini tahmin etmek aşağıdaki şekilde tanımlanır (Palit ve Popovic, 2005):

- Bir zaman serisinin $x_1, x_2, x_3, \dots, x_n$ şeklindeki gözlemlenen değerler kümesi göz önüne alındığında, gelecekteki x_{n+1}, x_{n+2}, \dots değerleri tahmin edilmelidir.
- n zaman noktasında hesaplanan q adım ilerideki x_{n+q} tahmini, $x^n(q)$ ile gösterilir. Burada q tam sayısı tedarik zamanı (lead time) olarak adlandırılır.

3.1.1. Trend Analizi

Doğrusal bir eğilim gösteren satış verileriyle oldukça sık karşılaşılır. Böyle doğrusal bir eğilim gösteren satış verileri Şekil 3.3'de gösterilmektedir. Trend analizi tahmin tekniği, veri noktaları boyunca düz bir çizgiye uyar ve önümüzdeki döneme ilişkin bir tahmin vermek üzere satış trendini yansıtmak için bu düz çizgiyi kullanır (Lancaster ve Lomas, 1985).



Şekil 3.3. Örnek satış eğilimi grafiği (Lancaster ve Lomas, 1985).

Eğilim tahmini için genellikle doğrusal veya doğrusal olmayan regresyon kullanılır. Bu, zaman serisi verilerinin doğrusal, kuadratik veya üstel fonksiyon kullanılarak eğilim çizgisine uydurulmasına dayanır (Palit ve Popovic, 2005).

Bu yöntemin Basit Doğrusal Regresyon Yönteminden tek farkı X bağımsız değişkeninin zaman olmasıdır. Basit Doğrusal Regresyon Yönteminde olduğu gibi bu yöntemde de a ve b değerleri hesaplanarak (X değişkeni olarak aylar alınarak) $\hat{Y}_i = a + bX_i$ denklemi bulunur (Yavuz, 2013).

a ve b değerleri Denklem 3.1 ve 3.2'deki formüller kullanılarak hesaplanır:

$$b = \frac{(T \sum_{i=1}^T X_i Y_i) - (\sum_{i=1}^T X_i \sum_{i=1}^T Y_i)}{(T \sum_{i=1}^T X_i^2) - (\sum_{i=1}^T X_i \sum_{i=1}^T X_i)} \quad (3.1)$$

$$a = \frac{\sum_{i=1}^T Y_i - b \sum_{i=1}^T X_i}{T} \quad (3.2)$$

X_i = Dönem

\hat{Y}_i = Tahmini kapanış değeri

T = Toplam dönem sayısı

3.1.2. Basit Ortalamalar Yöntemi

Bu yöntemde, önceki t dönemin gözlem değerlerinin basit aritmetik ortalaması bir sonraki dönemin, dönem $(t+1)$ in, öngörü değeri olarak alınabilir. Tahmin değerleri Denklem 3.3'deki formül kullanılarak hesaplanır (Yavuz, 2013).

$$\hat{Y}_{t+1} = \frac{\sum_{t=1}^T Y_t}{T} \quad (3.3)$$

3.1.3. Hareketli Ortalamalar Yöntemi

Sonlu mertebeden hareketli ortalama süreci, sonsuz derecede hareketli bir ortalama süreç olan Wold gösteriminin doğal ve açık bir yaklaşımasıdır. Sonlu mertebeden hareketli ortalama süreçleri de doğrudan motivasyona sahiptir. Zaman serilerindeki tüm değişmelerin, bir şekilde, çeşitli şoklar tarafından yönlendirilmesi, zaman serilerinin geçmişteki ve mevcut şokların dağınık gecikmeleri olarak -yani, hareketli ortalama süreçleri olarak- doğrudan modellenmesi olasılığını önermektedir. Bu yöntem, bir hareketli ortalama tahmini olarak bilinir. Çünkü ortalama, veri noktalarının çizgisinde hareket eder (Lancaster ve Lomas, 1985).

Bu yöntemde Y değişkeninin bir sonraki dönemde alacağı tahmini değer, o değişkenin geçmiş " T " dönemdeki ortalaması alınarak bulunur (Yavuz, 2013).

Hareketli ortalamanın cebirsel formülü Denklem 3.4'deki gibidir. (Yavuz, 2013):

$$\hat{Y}_i = \frac{Y_{i-1} + Y_{i-2} + \dots + Y_{i-n}}{n} \quad (3.4)$$

Hareketli Ortalamalar Yönteminde n değerinin nasıl seçileceği konusunda uyulacak genel bir kural yoktur. Genellikle 2 ile 7 arasında değişen farklı n değerleri alınarak, en düşük ortalama tahmin hatasını (tahmin değerleri ile gerçekleşen değerler arasındaki fark) veren n değeri tercih edilir (Yavuz, 2013).

Tahmin edilecek nesnenin zaman içinde oldukça istikrarlı kalacağını varsayabiliyorsa, hareketli ortalamalar kullanışlıdır (Samonas, 2015).

3.1.4. Üstel Düzeltme Yöntemi

Üstel Düzeltme Yöntemi de Hareketli Ortalama Tahmin Yöntemindeki amaca benzer bir amaç taşır. Aralarındaki farkı kısaca belirtmek mümkündür. Üstel Düzeltme Tahmin

Yöntemi, tüm tarihi verileri göz önünde bulundurur. Ancak, iterasyon sayısı arttıkça geçmişe daha az ağırlık verir. Hareketli Ortalama, eski dönemleri bütünüyle görmezden gelmekte, yalnızca Hareketli Ortalama dönemindeki tarihi verilere eşit ağırlık vermektedir (Gülle, 2016).

Üstel Düzeltme Yöntemi, bir bakıma, tüm tarihi verilerin hareketli ortalaması olmaktadır. Üstel Düzeltme Yönteminin kullanılmasındaki temel düşünce, talepte rassal dalgalanmaların etkilerini gidererek, genel yönetime uygun bir tahminde bulunabilmektir (Palamutçuoğlu, 2014).

Düzeltme katsayısı α , 0 ve 1 arasında bir değerdir. Küçük bir değer, örneğin 0.05 ile 0.10 arasındaki bir değer, yüksek derecede pürüzsüzlük oluşturur ve hareketli bir ortalama hesaplamasında çok sayıda gözlem ile aynı etkiye sahiptir. Yüksek bir katsayı değeri, daha az düzgünlükle ve dolayısıyla verilerin varyasyonlara karşı yüksek tepki vermesi ile sonuçlanır. Uç noktaları konuşmak gerekirse, eğer katsayı sıfırsa bir sonraki dönemin tahmini, geçen dönemin tahmini ile aynı olacak ve eğer katsayısı bir ise, bir sonraki dönemin tahmini, bulunulan dönem verileriyle aynı olacaktır (Nugus, 2005).

Basit üstel düzeltme için cebirsel formül Denklem 3.5'deki gibidir.

$$F_{t+1} = \alpha y_t + (1 - \alpha)F_t \quad (3.5)$$

burada, F_{t+1} = Yeni tahmin, F_t = Bir önceki tahmin, α = Düzeltme faktörü ve y_t = Gerçekleşen aylık kapanış değeridir.

Özalp ve Anagün (2001), hisse senedi fiyat tahmini için yapmış oldukları çalışmada klasik tahminleme yöntemlerinden Çoklu Doğrusal Regresyon Modelleri, Üstel Düzeltme ve Box Jenkins Modelleri'ni (ARIMA) karşılaştırmışlardır. Yöntemlerin tahminleme performanslarına genel olarak bakılacak olursa, en kötü değerlerin Çoklu Doğrusal Regresyon Modellerine ait olduğu gözlenmiştir. Hisse senedi fiyat tahmini probleminde, ortalama tahmin hatası değeri temelinde en tutarlı sonuçları üreten tahminleme yöntemlerinin, Üstel Düzeltme Yöntemi olduğu görülmektedir. Bu yüzden bu çalışmada Zaman Serileri Analizinde Çoklu Doğrusal Regresyon Modelleri ve Box Jenkins Modelleri'ni incelemeye gerek duyulmamıştır.

3.2. Yapay Zeka ve Sezgisel Algoritmalar

Yapay Zeka ve sezgisel algoritmalar oldukça geniş bir kullanım alanına sahiptir. Tahmin amaçlı kullanımda ise Genetik Algoritmalar, Destek Vektör Makineleri (Tay ve Cao, 2001) ve Yapay Sinir Ağları oldukça yaygın kullanılan teknikler arasında bulunmaktadır.

Genetik Algoritmalar, en başta Charles Darwin 1858 tarafından ortaya konulan, özellikle de en iyi olanın hayatta kalması olarak ortaya atılan evrim yöntemlerini kullanarak optimizasyon problemlerini çözer. Genetik algoritmalar, sinir ağlarına girdileri optimize etmek, stoklar evreninden bir portföy seçmek ve güvenlik piyasasında zaman ve fiyat hedefleri belirlemek için kullanılabilir (Gately, 1998).

Destek Vektör Makineleri (DVM), yapısal risk minimizasyonu prensibine göre çalışan dış bükey optimizasyona dayalı makine öğrenmesi algoritmalarıdır (Soman, Loganathan ve Ajay, 2011). DVM, örüntü tanıma ve sınıflandırma problemlerinin çözümü için Vapnik tarafından geliştirilmiştir (Cortes ve Vapnik, 1995). Fakat DVM olasılıksal tahminler üretmez, kategorik tahminler yapabilir (Var-Yok, A-Sınıfı, B-Sınıfı vb.). Kim (2003), Yapmış olduğu çalışmada, Destek Vektör Makinelerini kullanarak hisse senedi fiyat endeksinde günlük fiyat değişiminin yönünü tahmin etmeye çalışmıştır. Bir sonraki günün endeksinin bugünkünden daha düşük olması durumunu '0' ile, daha yüksek olması durumunu '1' ile ifade etmiştir.

Yapay Sinir Ağları, eğilimi değişecek olan desenleri tanımak ve hisse senedi fiyatlarının gelecekteki 5 veya 10 döneminlik değerini tahmin etmek gibi gelecekteki olayları tahmin etmek için kullanılır. Sinir ağları gelecekteki olayları tahmin etmede çok iyi olduğundan, fiyat ve zaman hedeflerini tahmin etmek için de kullanılabilir (Gately, 1998).

İleri beslemeli sinir ağları genellikle zaman serileri tahmininde kullanılır. Bazı durumlarda geri beslemeli ağlar da kullanılır. Araştırmacılar, gözlemlerde karmaşık doğrusal olmayan ilişkileri keşfetme kabiliyeti nedeniyle (Czibula ve diğerleri 2013; Donaldson ve Kamstra 1996; Indro vd.,1999), elektrik yükü tahmini (Taylor ve Buizza 2002), kısa vadeli yağış tahminleri (Kuligowski ve Barros 1998), kredi notu tahminleri (Kumar ve Bhattacharya 2006), turizm talebi tahminleri (Law, 2000) gibi çeşitli tahmin problemlerinde YSA kullanmaktadırlar. Wilson vd. (2002), tarafından yazılmış makalede YSA uygulamaları (özellikle Geri Yayılım Ağları (BPNN)) hakkında daha ayrıntılı açıklama bulunabilir (Singh, 2016).

4. YAPAY SİNİR AĞLARI

4.1. YSA'nın Tanımı

Beyin en mükemmel ve en iyi organize edilmiş işlem yapısına sahip olma özelliğini her zaman korumuştur ve günümüzdeki ve gelecekteki araştırmalar için taklit edilmesi en çok ilgi çeken konulardan birisidir. Beynin işleme felsefesini incelemek ve yapısını taklit ederek özelliklerini kopyalamak, bilim insanlarının son 50 yılda gerçekleştirmeye çalıştıkları düşüncedir (Arena vd., 1998).

Yapay sinir ağları, adından da anlaşılacağı üzere, biyolojik (insan veya hayvan) merkezi sinir sisteminin sinir hücresi ağlarını (nöronlar) ciddi bir şekilde taklit etmeye çalışan hesaplama ağlarıdır. Bu simülasyon, hücreler arası büyüklükte (nörondan nörona, elementten elemente) bir benzetimdir. Biyolojik nöronların nörofizyolojik bilgisinden ve böyle biyolojik nöronların ağlarından esinlenir (Graupe, 1997).

Sinir ağları insan beynine benzerlik gösterse de, onu modellemek için tasarlanmamıştır. Sorun çözme ve bilgi mühendisliği için "insana benzer" bir yolla yararlı modeller olmaları amaçlanmaktadır. İnsan beyni çok daha karmaşıktır ve ne yazık ki bilişsel fonksiyonlarının çoğu hala tam olarak bilinmemektedir. Fakat insan beyni ne kadar çok öğrenilirse, o kadar iyi hesaplama modelleri geliştirilir ve pratikte kullanılmaya başlanır. Bu nedenle, insan beyninin temel özelliklerine bilgi-işleme bakış açısından bakmak ve bu özelliklerin yapay sinir ağlarında ne ölçüde gerçekleştirildiğini anlamak için uğraşılır (Kasabov, 1996).

Bir yapay sinir ağı (YSA), biyolojik sinir ağları ile ortak belli performans özelliklerine sahip bir bilgi-işleme sistemidir. Yapay sinir ağları, insan bilişinin veya sinirsel biyolojinin matematiksel modellerinin genelleştirilmesi olarak geliştirilmiş olup, şu varsayımlara dayanmaktadır (Yadav vd., 2015):

- (i) Bilgi işleme, nöron adı verilen birçok basit bağlantıda gerçekleşir.
- (ii) Sinyaller bağlantı linkleri üzerinden nöronlar arasında iletilir.
- (iii) Her bir bağlantı hattı, tipik sinir ağı içinde iletilen sinyali çarpan ilişkili bir ağırlığa sahiptir.
- (iv) Her bir nöron, çıkış sinyalini belirlemek için net girişe bir aktivasyon fonksiyonu uygular.

Birçok basit işlem elemanı (nöronlar) arasındaki muazzam işbirliği, geleneksel hesaplama yapılarında karşılığı bulunmayan çok ilginç özelliklerin ortaya çıkmasına neden olur. Bu özellikler şunlardır (Arena vd., 1998):

- a. **Sağlamlık ve hata toleransı:** Birkaç nöron beyin verimliliğini çok fazla etkilemeksizin her gün ölür;
- b. **Esneklik:** Çevreden öğrenme kabiliyetinden kaynaklanan uyum için büyük bir kapasiteye sahiptir;
- c. **Veri birleştirme yeteneği:** Çevresel ipuçlarından kurallar çıkarma yeteneğine sahip olduğu için farklı bilgi türleri ile eşzamanlı olarak uyum sağlayabilir;
- d. Yüksek sayısal hassasiyetle açıklanan bilgileri gerektirmez; bulanık veya gürültülü olabilir.

YSA'lar insanlara benzer şekilde örnekle öğrenirler. Öğrenme işlemi, YSA'yı örüntü tanıma veya veri sınıflandırma gibi belirli bir uygulama için yapılandırır. Biyolojik sistemlerde öğrenmek, YSA'lar için de geçerli olan nöronlar arasındaki sinaptik bağlantıları ayarlamayı gerektirir (Terzic vd., 2012).

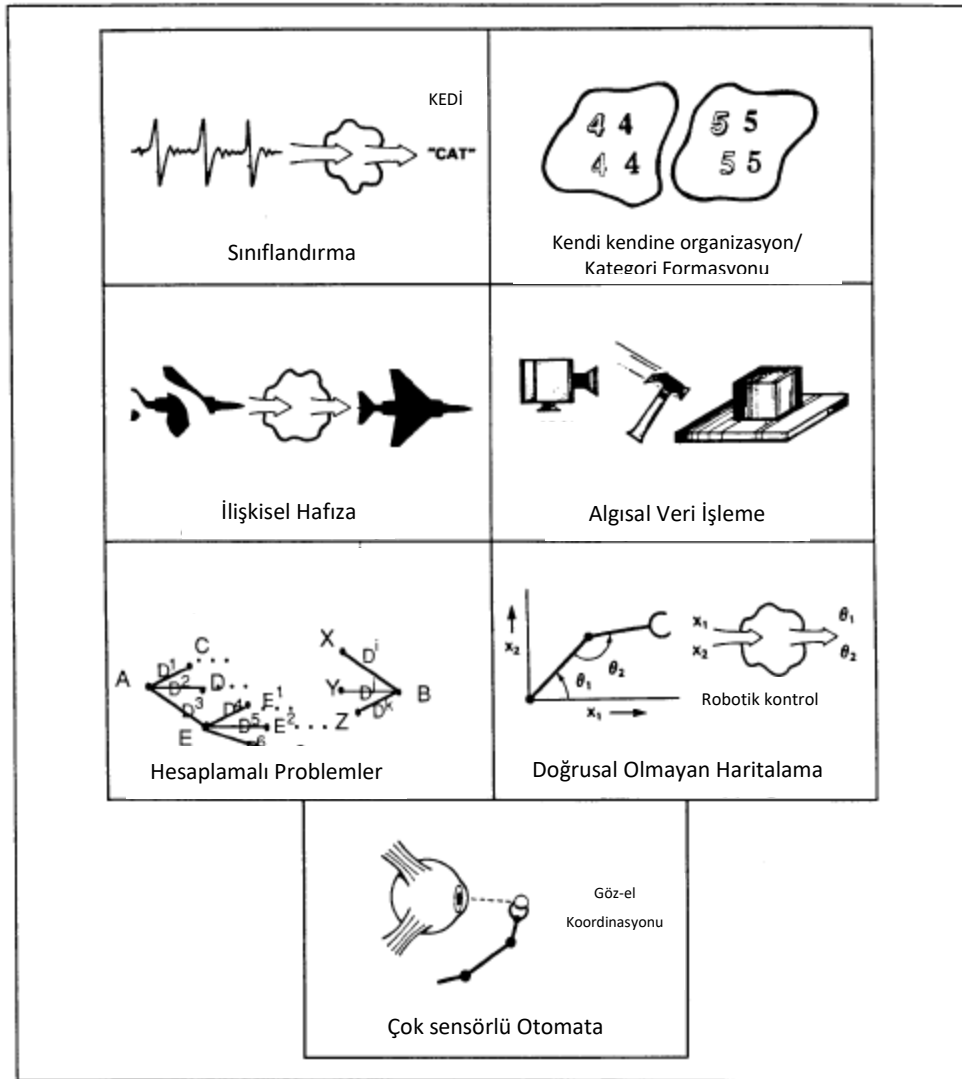
'Gelişmekte olan' bir nöron plastik bir beyin ile eş anlamlıdır: Plastiklik, gelişmekte olan sinir sisteminin çevresindeki çevreye uyum sağlamasına izin verir. Plastiklik, insan beynindeki bilgi işleme birimleri olarak nöronların işleyişi için gerekli gibi görünür, bu nedenle yapay nöronlardan oluşan sinir ağları ile yapılır. En genel biçiminde bir sinir ağı, beynin belirli bir görev veya ilgisini gerçekleştirme biçimini modellemek üzere tasarlanmış bir makinadır; ağ genellikle elektronik bileşenler kullanılarak uygulanır veya bir dijital bilgisayarda yazılımla simüle edilir (Haykin, 1999).

Yapay sinir ağları (YSA), ya da sadece sinir ağı, insan beynini taklit etme fikrine göre geliştirilen bir makine öğrenme metodudur. Geleneksel bir regresyon yaklaşımıyla karşılaştırıldığında YSA, karmaşık doğrusal olmayan ilişkileri modelleme yeteneğine sahiptir (Livingstone, 2009).

Sinir ağlarına ilgi duyulmasının tarihsel olarak iki nedeni vardır: (1) insan beyninin çalışma prensiplerini anlama arzusu ve (2) ardışık çalışan, programlanabilir bilgisayarlar için karmaşık görevler yapabilen makineleri inşa etme arzudur (Müller vd., 1995).

4.2. YSA'nın Uygulama Alanları

Yapay sinir ağlarının kullanıldığı uygulama alanları her geçen gün artmaktadır. Şekil 4.1'de gösterildiği gibi, desen tanımlama, sınıflandırma, optimizasyon, özellik algılama, veri sıkıştırma, yaklaşma, ilişkilendirme, tahmin, kontrol sinir ağlarının kullanıldığı problem çeşitlerine örnek olarak gösterilebilir (Fyfe, 2000).



Şekil 4.1. YSA ile gerçekleştirilebilecek görevler (Architecture Technology Corporation, 1991).

YSA, havacılık, otomotiv, banka, savunma, elektronik, eğlence, finans, sigorta, imalat, sağlık, petrol ve gaz, robotik, konuşma, menkul kıymetler, telekomünikasyon, ulaşım alanlarında yaygın olarak kullanılmaktadır (Hagan vd., 2014).

Finans: Gayrimenkul değerlemesi, kredi danışmanı, ev kredisi taraması, kurumsal tahvil derecelendirme, kredi hattı kullanımı analizi, portföy ticaret programı, kurumsal finansal analiz, döviz fiyatı tahmini (Fyfe, 2000).

Menkul Kıymetler: Piyasa analizi, otomatik tahvil derecelendirme, hisse ticareti danışmanlık sistemleri (Fyfe, 2000).

4.3. YSA'nın Avantajları ve Dezavantajları

Sinir ağları aşağıdaki yararlı özellikleri ve yetenekleri sunar (Haykin, 2008):

1. Doğrusal Olmama: Yapay bir nöron doğrusal olabilir veya doğrusal olmayabilir. Doğrusal olmayan nöronların birbirine bağlanmasından oluşan bir sinir ağı, doğrusal değildir. Üstelik doğrusal olmama, ağ boyunca dağıtıldığı anlamda özel bir türdür. Bu yüzden doğrusal olmayan problemlerde oldukça kullanışlıdır.

2. Girdi-Çıktı Eşleme: Bir öğretmen ya da denetleme ile öğrenme aracılığıyla öğrenme denilen popüler bir öğrenme paradigması, etiketli *eğitim örnekleri* ya da *görev örnekleri* seti uygulayarak sinir ağının sinaptik ağırlıklarının değiştirilmesini içerir. Her örnek, benzersiz bir *giriş sinyalinin* ve karşılık gelen *istenilen (hedef) yanıtın* oluşur.

3. Uyarılma: Sinir ağları, sinaptik ağırlıkları çevredeki değişikliklere uyarlamaya yönelik yerleşik bir kabiliyete sahiptir. Özellikle belirli bir çevrede çalışmak üzere eğitilmiş bir sinir ağı, çalışma ortam koşullarındaki minör değişiklikler ile başa çıkmak için kolayca yeniden eğitilebilir.

4. Kanıtı Dayalı Cevap: Desen sınıflandırması kapsamında, sadece seçmek için hangi desen hakkında bilgi verileceği değil, aynı zamanda alınan karara güven hakkında da bir sinir ağı tasarlanabilir. Bu son bilgiler, ortaya çıktıklarında belirsiz desenleri reddetmek ve böylece ağın sınıflandırma performansını arttırmak için kullanılabilir.

5. İçeriksel Bilgi: Bilgi, sinir ağının yapısı ve aktivasyon durumu ile temsil edilir. Ağdaki her nöron, ağdaki diğer tüm nöronların küresel faaliyetinden potansiyel olarak etkilenir. Sonuç olarak, içeriğe dayalı bilgiler bir sinir ağıyla ele alınır.

6. Hata Toleransı: Donanım biçiminde uygulanan bir sinir ağı, olumsuz çalışma koşulları altında performansının zararsız olarak azalmasıyla, doğal olarak hataya dayanıklı veya

güçlü hesaplama kabiliyeti potansiyeline sahip olur. Örneğin, bir nöron veya bağlantıları hasar görürse, depolanmış bir desenin çağırılması kalite bakımından bozulmaya yol açar.

7. Çok Geniş Ölçekli Tümeleşim (VLSI) Uygulanabilirliği: Sinir ağının kitlesel olarak paralellik doğası, ağın bazı görevlerin hesaplanması için potansiyel olarak hızlı olmasını sağlar. Bu aynı özellik, sinir ağını, çok geniş ölçekli entegre (VLSI) teknolojiyi kullanarak uygulamaya çok uygun hale getirir. VLSI'nin özellikle yararlı bir özelliği, gerçekten karmaşık davranışı son derece hiyerarşik bir biçimde yakalamak için bir araç sağlamasıdır (Mead, 1989).

8. Analiz ve Tasarım Eşitliği: Temel olarak, sinir ağları bilgi işlemcileri olarak evrenselidirler. Aynı gösterimin sinir ağlarının uygulanmasını içeren tüm alanlarda kullanılmasından dolayı bu varsayımı ulaşılabilir.

9. Nörobiyolojik Analoji: Bir sinir ağı tasarımı, hataya dayanıklı paralel işlemenin sadece fiziksel olarak mümkün olmadığı, aynı zamanda hızlı ve güçlü olduğunun canlı kanıtı olan beyin benzetmesiyle motive edilir. Nörobiyologlar (yapay) sinir ağlarına nörobiyolojik olayların yorumlanması için bir araştırma aracı olarak bakarlar. Öte yandan, mühendisler, geleneksel kablolu tasarım tekniklerine dayanan problemlerden daha karmaşık olan problemleri çözmek için yeni fikirler için nörobiyolojiye başvurumaktadırlar.

Listelenen faydalara ek olarak, paralel dağıtılmış işleme ve genelleme kabiliyeti birincil özellikler olarak belirtilmelidir (Flores, 2011).

YSA'daki **paralel dağıtılmış işleme**, biyolojik analogiden gelir ve YSA'nın temel özelliğidir. Doğrusal olmayanlık, girdi-çıkı haritalama, hata toleransı ve VLSI uygulanabilirliği gibi birçok özellik, doğal olarak paralel dağıtılmış işleme kaynaklanmaktadır.

Genelleme kabiliyeti, veriden genel bilgi çıkarma özelliğidir. Yeterince eğitilirse YSA bu görevin üstesinden gelebilir.

YSA'ların, pek çok avantajın yanında bazı dezavantajları da vardır. Belli başlı dezavantajları (<http://www.ibrahimcayiroglu.com>);

1. Donanım bağımlıdır. YSA'ların en önemli sorunu donanım bağımlı olmalarıdır. YSA'ların en önemli özellikleri ve var oluş nedenlerinden birisi olan paralel işlem yapabilme yeteneği, paralel çalışan işlemciler ile performans gösterir.

2.Uygun ağ yapısının belirlenmesinde belli bir kural yoktur. YSA'larda probleme uygun ağ yapısının belirlenmesi için geliştirilmiş bir kural yoktur. Uygun ağ yapısı deneyim ve deneme yanılma yolu ile belirlenmektedir.

3.Ağın parametre değerlerinin belirlenmesinde de belli bir kural yoktur. YSA'larda öğrenme katsayısı, hücre sayısı, katman sayısı gibi parametrelerin belirlenmesinde belirli bir kural yoktur. Bu değerlerin belirlenmesi için belirli bir standart olmamakla birlikte her problem için farklı bir yaklaşım söz konusu olabilmektedir.

4.Öğrenilecek problemin ağa gösterimi önemli bir problemdir. YSA'lar nümerik bilgiler ile çalışabilmektedirler. Problemler YSA'lara tanıtılmadan önce nümerik değerlere çevrilmek zorundadırlar. Burada belirlenecek gösterim mekanizması ağın performansını doğrudan etkileyecektir. Bu da kullanıcının yeteneğine bağlıdır.

5.Ağın eğitiminin ne zaman bitirilmesi gerektiğine ilişkin belli bir yöntem yoktur. Ağın örnekler üzerindeki hatasının belirli bir değerin altına indirilmesi eğitimin tamamlandığı anlamına gelmektedir. Burada ideal neticeler veren bir mekanizma henüz yoktur ve YSA ile ilgili araştırmaların önemli bir kolunu oluşturmaktadır.

6.Ağın davranışları açıklanamamaktadır. Bu sorun YSA'ların en önemli sorunudur. YSA bir probleme çözüm ürettiği zaman, bunun neden ve nasıl olduğuna ilişkin bir ipucu vermez. Bu durum ağa olan güveni azaltıcı bir unsurdur.


7.Açık bir model olmadığı için verilerin çok fazla anlaşılmasına izin vermemesidir. Sinir ağları tahmin için bir "kara kutu" yaklaşımı sağlar. Diğer kara kutu tahminleri açısından bakıldığında, bu tahminler açık model temelli bir yaklaşımın başarısız olduğu durumlarda çalışabilirler (Makridakis vd., 1997).

4.4. Biyolojik Sinir Hücresinin Yapısı

Yapay sinir ağı, insan beyni gibi biyolojik nöronların mimarisinden esinlenmiştir. İnsan beyni çok sayıda birbirine bağlı nöronlardan oluşur (Cartwright, 2009). Nöral hücrelerin iç yapısının ayrıntılı incelenmesi, özellikle 50 yıl önce elektron mikroskobu icadından sonra, tüm nöronların büyüklük ve şekillerinden bağımsız olarak aynı temel parçalardan yapıldığını ortaya koymuştur (Müller vd., 1995).

Nöronlar olarak adlandırılan sinir hücreleri, merkezi sinir sisteminin temel unsurlarıdır. Merkezi sinir sistemi yaklaşık 5 milyar nörondan oluşur. Nöronlar, genel organizasyonlarında ve biyokimyasal sistemlerinde diğer hücelere göre çok sayıda noktaya sahiptir ve aynı zamanda birçok farklı özelliğe sahiptirler (Davalo ve Naım, 1991).

Nöronların beş uzman fonksiyonu vardır: komşu nöronlardan gelen sinyalleri alır, bu sinyalleri birleştirirler, sinir titreşimlerinin oluşmasını sağlarlar, bu titreşimleri yönetirler ve bunları alan diğer nöronlara iletirler (Davalo ve Naım, 1991).

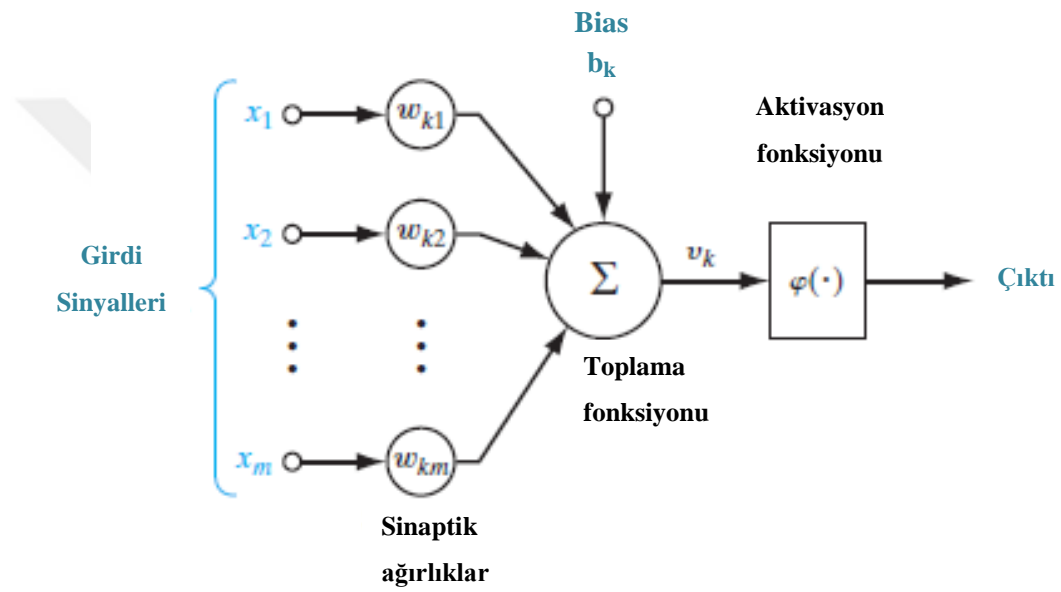


Şekil 4.2. Biyolojik bir nöron (Mehrotra vd., 1997).

Bir nöron, Şekil 4.2'de gösterildiği gibi dendritler, bir hücre gövdesi ve bir aksondan oluşur. Soma olarak da adlandırılan hücre gövdesi, tıpkı diğer hücreler gibi çekirdeğe sahiptir. Dendritler, hücre gövdesine bağlanan ve uzayda diğer nöronlardan sinyalleri almak için uzanan dallardır. Akson, nöronun ileticisidir. Komşu nöronlara sinyal gönderir. Bir nöronun aksonunun bitişi ile komşu nöronun dendritleri arasındaki bağlantı, iki nöron arasındaki iletişim birimi olan sinaps olarak adlandırılır. Elektrokimyasal sinyaller sinaps boyunca iletilir. Bir sinirin aldığı toplam sinyal sinaps eşliğinden yüksek olduğunda sinir hücrelerini ateşlemesine, yani komşu sinir hücrelerine elektrokimyasal bir sinyal göndermesine neden olur. Sinaptik bağlantının gücünün değiştirilmesinin belleğin temeli olduğu varsayılmaktadır (Cartwright, 2009).

4.5. Yapay Sinir Hücresinin Yapısı

Biyolojik sinir ağlarının sinir hücreleri olduğu gibi yapay sinir ağlarının da yapay sinir hücreleri vardır. Yapay sinir hücreleri mühendislik biliminde proses elemanları olarak da adlandırılmaktadır. Şekil 4.3'te gösterildiği gibi her proses elemanın 5 temel elemanı vardır. Bunlar; girdiler, ağırlıklar, toplama fonksiyonu, aktivasyon fonksiyonu ve çıktılarıdır (Öztemel, 2012).



Şekil 4.3. Bir nöron modeli (Haykin, 2008).

Bir biyolojik nöron hesaplama yapmak için yapay olarak modellenebilir ve daha sonra model, yapay nöron olarak adlandırılabilir (Yadav vd., 2015).

Biyolojik nöronların ve YSA'nın işleme elemanlarının aktiviteleri Çizelge 4.1'deki gibi karşılaştırılabilir (Flores, 2011).

Çizelge 4.1. Nöronlar ve işleme elemanları (PE)nın benzerlikleri (Flores, 2011).

Nöronlar	İşleme Elemanları (PE)
Sinapslar	Ağırlıklar
Dendritler	Toplama Fonksiyonu
Hücre Gövdesi	Aktivasyon Fonksiyonu
Akson	Çıktı
Eşik değeri	Bias

Yapay sinir ağlarının işleme elemanlarının birkaç temel özelliği, biyolojik nöronların özellikleriyle aşağıdaki gibi öne sürülmüştür (Fausett, 1994):

1. İşleme elemanı birçok sinyal alır.
2. Sinyaller alıcı sinapsta bir ağırlık tarafından değiştirilebilir.
3. İşleme elemanı ağırlıklandırılmış girdileri toplar
4. Uygun koşullar altında (yeterli girdi) nöron tek bir çıktı iletir.
5. Belirli bir nörondan çıkan çıktı, akson dallarının başka birçok nöronuna gidebilir.

4.5.1. Girdiler


Girdiler nöronlara gelen verilerdir. Girdiler yapay sinir hücresine bir diğer hücreden gelebileceği gibi direk olarak dış dünyadan da gelebilir. Bu girdilerden gelen veriler biyolojik sinir hücrelerinde olduğu gibi toplanmak üzere nöron çekirdeğine gönderilir (<http://www.ibrahimcayiroglu.com>).

4.5.2. Ağırlıklar

Bilgiler, bağlantılar üzerindeki ağırlıklar üzerinden hücreye girer ve ağırlıklar, ilgili girişin hücre üzerindeki etkisini belirler. Ağırlıklar bir nöronda girdi olarak kullanılacak değerlerin göreceli kuvvetini (matematiksel katsayısını) gösterir. Yapay sinir ağı içinde girdilerin nöronlar arasında iletimini sağlayan tüm bağlantıların farklı ağırlık değerleri bulunmaktadır. Böylelikle ağırlıklar her işlem elemanının her girdisi üzerinde etki yapmaktadır (<http://bm.bilecik.edu.tr>).

4.5.3. Toplama fonksiyonu

Toplama fonksiyonu bir yapay sinir hücresine ağırlıklarla çarpılarak gelen girdileri toplayarak o hücrenin net girdisini hesaplayan bir fonksiyondur (<http://www.ibrahimcayiroglu.com>).



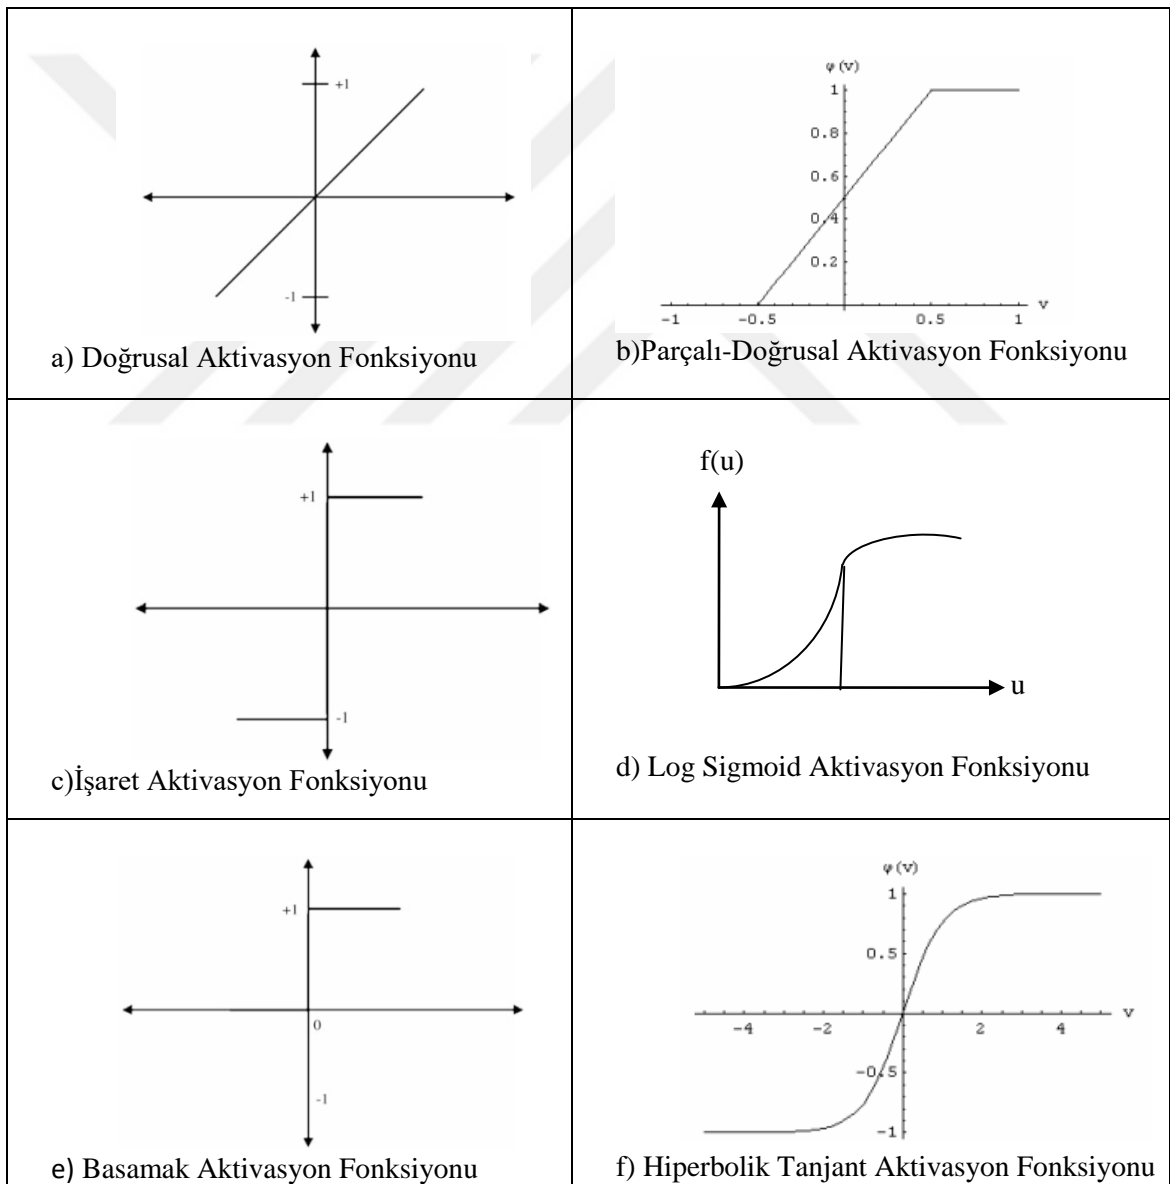
Şekil.4.4. Ağırlıklı girdi toplama (Mehrotra vd., 1997).

Bazı durumlarda gelen girdilerin değeri dikkate alınırken bazı durumlarda ise gelen girdilerin sayısı önemli olabilmektedir. Bir problem için en uygun toplama fonksiyonu belirlenirken geliştirilmiş bir yöntem yoktur. Genellikle deneme yanılma yoluyla toplama fonksiyonu belirlenmektedir. Bazen her hücrenin toplama fonksiyonunun aynı olması gerekmez. Bu konulara karar vermek tasarımcıya aittir. Bazı toplama fonksiyonları; toplam fonksiyonu, çarpım fonksiyonu, enbüyük fonksiyonu, enküçük fonksiyonu, çoğunluk fonksiyonu, kümülatif toplam, net fonksiyonudur. Bu çalışmada toplam fonksiyonu kullanılmıştır. Bu fonksiyonda ağırlık değerleri girdiler ile çarpılır ve bulunan değerler birbirleriyle toplanarak Net girdi Denklem 4.1'deki gibi hesaplanır (<http://www.ibrahimcayiroglu.com>).

$$\text{Net} = \sum_{i=1}^N X_i * W_i \quad (4.1)$$

4.5.4. Aktivasyon fonksiyonu

Yapay bir nöronun temel işlemi, ağırlıklandırılmış girdi sinyalinin toplanması ve bir çıktı veya aktivasyon fonksiyonu uygulanmasını içerir. Girdi birimleri için bu fonksiyon, tanımlama fonksiyonudur. Genellikle, aynı aktivasyon işlevi, sinir ağının belirli bir katmanındaki tüm nöronlar için kullanılır, ancak bu gerekli değildir. Çoğu durumda, doğrusal olmayan bir aktivasyon fonksiyonu kullanılır (Fausett, 1994). Yaygın olarak kullanılan aktivasyon fonksiyonları Şekil 4.5'te gösterilmektedir.



Şekil 4.5. Aktivasyon fonksiyonu çeşitleri (Yadav vd., 2015; Hajek, 2005; Priddy ve Keller, 2005).

Bu çalışmada, veriler pozitif değerli olduğu ve fonksiyon doğrusal olmadığı için aktivasyon fonksiyonu olarak log sigmoid aktivasyon fonksiyonu kullanılmıştır.

En yaygın transfer fonksiyonu, Denklem 4.2’de verilen lojistik sigmoid fonksiyonudur (Priddy ve Keller, 2005):

$$çikti = \frac{1}{1+e^{-(\sum_i w_i x_i + w_0)}} \quad (4.2)$$

burada, i , nörona ait girdilerin indeksi; x_i , nöronun girdisi; w_i , nörona bağlı ağırlık faktörü ve w_0 , nöronun biasıdır (hata terimidir).

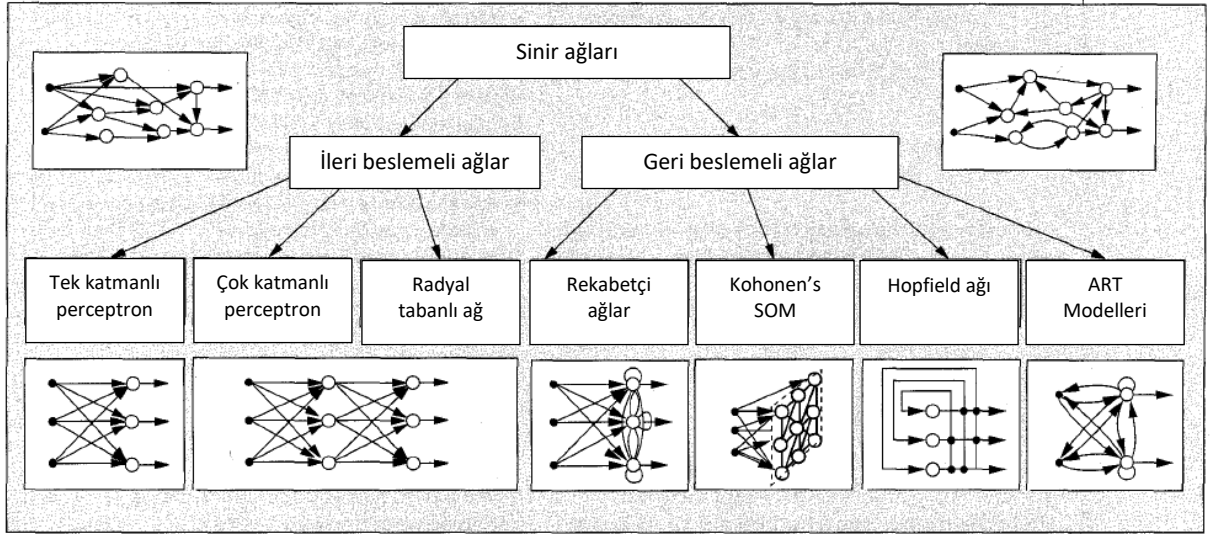
4.5.5. Çıktı

Aktivasyon fonksiyonundan çıkan değer, hücrenin çıktı değeri olmaktadır. Bu değer ister yapay sinir ağının çıktısı olarak dış dünyaya verilir isterse tekrardan ağın içinde kullanılabilir. Her hücrenin birden fazla girdisi olmasına rağmen bir tek çıktısı olmaktadır. Bu çıktı istenilen sayıda hücreye bağlanabilir (<http://www.ibrahimcayiroglu.com>).

4.6. Yapay Sinir Ağlarının Sınıflandırılması

4.6.1. YSA’ların yapılarına göre sınıflandırılması

Şekil 4.6’da verildiği gibi, ağdaki geribildirim bağlantılarının varlığına veya yokluğuna göre, iki tür mimari bulunmaktadır (Kasabov, 1996).

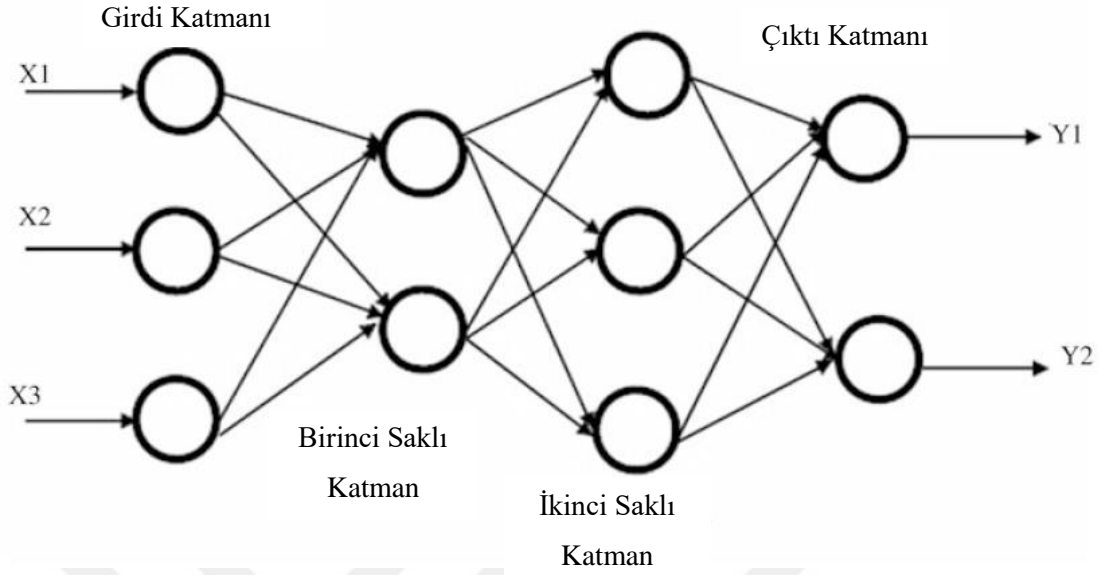


Şekil 4.6. İleri-geri besleme ve tekrarlayan / geribildirim ağ mimarisinin bir taksonomisi (Jain ve Mao, 1996).

4.6.1.1. İleri Beslemeli Ağlar

İleri beslemeli sinir ağları, yapay sinir ağlarının en basit biçimidir. İleri beslemeli sinir ağı, tasarlanan yapay ağı ilk ve tartışmasız en basit türüdür (Yadav vd., 2015). Bir ileri beslemeli ağda, nöronlar genellikle katmanlara ayrılır (Pham ve Karaboga, 2000). Şekil 4.7'de gösterildiği gibi, bu ağda, bilgi girdi düğümlerinden, gizli düğümler (varsa) boyunca çıktı düğümlerine kadar sadece bir yönde ilerlemektedir (Yadav vd., 2015). Çıktıdan girdi nöronlarına hiçbir geri bağlantı yoktur; ağ önceki çıktı değerlerinin ve nöronlarının aktivasyon durumlarının hafızasını tutmaz (Kasabov, 1996). Sinyaller giriş katmanından çıktı katmanına tek yönlü bağlantılar yoluyla akar; nöronlar aynı katmandan değil bir katmandan bir sonraki katmana bağlanır. İleri beslemeli ağların örnekleri arasında, çok katmanlı algılayıcı (MLP) (Rumelhart ve McClelland, 1986), öğrenme vektörü kantifikasyonu (LVQ) ağı (Kohonen, 1989) ve veri taşıma grup yöntemi (GMDH) ağı (Hecht- Nielsen, 1990) bulunmaktadır. İleri beslemeli ağlar, en doğal şekilde, bir girdi alanı ve bir çıktı alanı arasında statik eşlemeler yapabilirler; belirli bir an içindeki çıktı, yalnızca o andaki girdinin bir fonksiyonudur (Pham ve Karaboga, 2000).

Diler (2003), yapmış olduğu çalışmada inceledikleri 40 makalenin 26'sında geri yayılım algoritmasının kullanıldığını tespit etmiştir. Bu çalışmada tahmin problemlerinde en çok kullanılan model olması sebebiyle ileri beslemeli geri yayımlı YSA'lar kullanılmıştır (Çalışkan ve Deniz, 2015).



Şekil 4.7. İleri-beslemeli bir ağ (Yadav vd., 2015).

4.6.1.2. Geri Beslemeli Ağlar

Tekrar eden bir ağ, çıktı düğümlerinden girdi düğümlerine geri dönen bağlantılara sahip olabilir ve aslında herhangi bir düğüm arasında keyfi bağlantılara da sahip olabilir. Bu sayede, tekrar eden bir ağın iç durumu, girdi verisi setleri sunulduğunda değişebilir ve bu ağın bir belleğe sahip olduğu söylenebilir. Bu, çözümün yalnızca mevcut girdilere değil, daha önceki tüm girdilere dayandığı sorunların çözümünde faydalıdır. Tekrar eden ağ öğrenirken, girdilerini ağ üzerinden gönderir; bunlara, veriden çıktılara ağ üzerinden girişlere besleme de dahildir ve çıktılarının değerleri değişmeden bu işlemi tekrarlar. Bu noktada, ağın denge veya istikrar halinde olduğu söylenmektedir (Yadav vd., 2015). Tekrarlayan ağ örnekleri arasında Hopfield ağı (Hopfield, 1982), Elman ağı (Elman, 1990) ve Jordan ağı (Jordan, 1986) bulunmaktadır. Tekrarlayan ağların dinamik bir belleği vardır; belirli bir an içindeki çıktıları, önceki girdi ve çıktıların yanı sıra mevcut girdiyi de yansıtmaktadır. Elman ve Jordan ağları normalde basit çalışırlar (Pham ve Karaboga, 2000).

4.6.2. YSA'ların öğrenme algoritmalarına göre sınıflandırılması

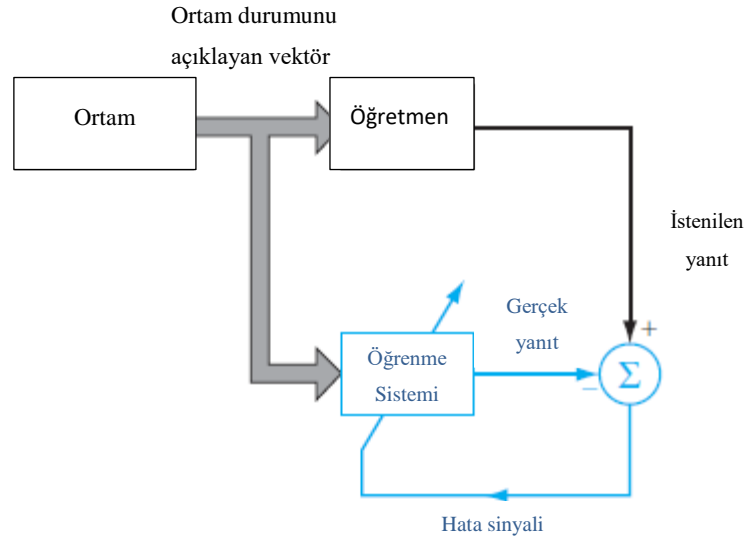
Sinir ağlarının yeni ortamlarla karşılaştıklarında programlanmasına gerek yoktur. Ancak davranışları, yeni ortama uyum sağlamak için değişir. Bu tür davranış değişiklikleri, ağdaki ağırlıklardaki değişikliklerden kaynaklanmaktadır. Ağırlıklardaki bu değişikliklere sinir ağında

öğrenme denilmektedir. Bir yapay sinir ağındaki ağırlıktaki değişiklikler, gerçek sinir ağlarında değişen sinaptik etkinliklerin modellenmesi ile tasarlanmıştır: Öğrenmemizin, sinapsların sinirler arasında bilgi aktarımı yaptığı verimlilikteki değişikliklerden kaynaklandığına inanılmaktadır. Sinir ağında 3 temel öğrenme türü vardır (Fyfe, 2000).

4.6.2.1. Danışmanlı öğrenme

Danışmanlı öğrenme, her iki vektöre ilişkin veriler içeren bir eğitim seti olduğunda, bir X vektöründen bir Y vektörüne statik bir eşleşme öğrenmesi anlamına gelmektedir. X vektörü bir desen içeriyorsa ve Y vektörü, eğitim setindeki her öge için bu örüntünün bir sınıflandırmasını içeriyorsa, danışmanlı öğrenme istatistiksel desen tanımlama ile ilgili araştırma yapan kişilerin yıllarca üzerinde çalıştığı bir göreve dönüşmektedir. Bununla birlikte, YSA'lar genelde, parametrelerini, bir veritabanında yineleme yerine, bir kerede, gerçek zamanlı öğrenmede ayarlamak için tasarlanmıştır (Kanal ve Rosenfeld, 1991).

Danışmanlı öğrenme algoritmaları, bir ağın girdi-çıkı özelliklerini istenilen özelliklerle eşleştirmek için girdi-çıkı verilerini kullanarak sinaptik ağırlıkları ayarlar. En sık kullanılan algoritma, geri yayılım algoritmasıdır (Ruan, 1997).



Şekil 4.8. Danışmanlı öğrenme blok diyagramı; şeklin mavi renk ile gösterilen kısmı bir geri besleme döngüsü oluşturur (Haykin, 2008).

Denetimli/danışmanlı öğrenme algoritmalarına örnek olarak, delta kuralı (Widrow and Hoff, 1960), genelleştirilmiş delta kuralı veya geri yayılım algoritması (Rumelhart ve

McClelland, 1986) ve LVQ algoritması (Kohonen, 1989) gösterilebilir. Standart otomatik ilişkisel Hopfield ağında öğrenme, denetimli öğrenmenin özel bir durumu olarak kabul edilebilir. Ağ, "öğrenme" esnasında özel bir-adımlı prosedürünü ve hatırlama sırasında tekrarlayıcı bir süreç uygular. Bu ağın aksine, diğer çoğu ağ öğrenme aşamasında yinelemeli bir süreç kullanmaktadır (Pham ve Karaboga, 2000).

4.6.2.2. Danışmansız öğrenme

Ağın çıktısı için denetlenen verilere göre ağırlıkları değiştiren danışmanlı öğrenmenin aksine danışmansız/denetimsiz öğrenme algoritmaları ağın girdi değerlerine göre sinaptik ağırlık değerlerini değiştiren mekanizmayı kullanır. Çıktı karakteristikleri, sinir ağının kendisi tarafından belirlendiğinden, bu mekanizmaya kendi kendini düzenleme adı verilmektedir. Hebbian öğrenme ve rekabetçi öğrenme, denetimsiz öğrenme algoritmalarına örnek olarak gösterilebilir (Ruan, 1997).

Danışmansız eğitim, etiketsiz eğitim verilerini kullanır ve harici öğretmen gerektirmez; veriler, girilen verileri sınıflandırma kategorilerine sıkıştırılan dahili kümeleri oluşturan ağa sunulur (Architecture Technology Corporation, 1991). Danışmansız öğrenme algoritmalarının örnekleri arasında, Kohonen (Kohonen, 1989) ve Carpenter-Grossberg Uyarlamalı Rezonans Teorisi (ART) (Carpenter ve Grossberg, 1988) rekabetçi öğrenme algoritmaları bulunmaktadır (Pham ve Karaboga, 2000).

Danışmanlı paradigmanın aksine, modellerin sınıflandırılacağı bir ön kategori seti bulunmamaktadır; bunun yerine sistem girdi uyarılarının kendi gösterimini geliştirmelidir (Kröse ve Smagt, 1996).

4.6.2.3. Destekli öğrenme

Destekli öğrenme, danışmanlı öğrenmeyle benzerdir, ancak eğitim setinde hedef Y vektörlerinin olduğu varsayımı bulunmamaktadır. Bunun yerine, ağın mevcut çıktılarının ne kadar iyi olduğunu bildiren bir performans hakimi veya fayda fonksiyonunun kullanılabilmesi varsayılmaktadır. Özünde, danışmanlı öğrenme bir çocuğa nereye gideceğini (arka bahçesindeki iki boyutlu Y boşluğunda) anlatmak gibidir; buna karşın destekli/takviyeli öğrenme ise ona bir hedeften "daha soğuk" veya "daha sıcak" olduğunu söylemek gibidir (Kanal ve Rosenfeld, 1991). Destekli öğrenme algoritmasına bir örnek olarak Genetik Algoritma (GA) verilebilir (Holland, 1975; Goldberg, 1989; Pham ve Karaboga'dan (2000)).

4.6.3. Uygulamaya göre öğrenme algoritmaları

4.6.3.1. Çevrimiçi (online) öğrenme

Bu kurala göre öğrenen sistemler, gerçek zamanda çalışırken bir taraftan fonksiyonlarını yerine getirmekte, diğer taraftan da öğrenme işlemine devam etmektedir. Eğer değişkenler her bir verinin sunulmasından sonra güncelleştirilirse, çevrimiçi öğrenme örneği elde edilmiş olur. Bu öğrenme yöntemi değişen karakteristiğe sahip sistemler için, çevrimiçi değişken tanımlanması açısından önemlidir (Öztemel, 2012).

4.6.3.2. Çevrimdışı (offline) öğrenme

Bu kurala dayalı sistemler kullanıma alınmadan önce örnekler üzerinde eğitilirler. Bu kuralı kullanan sistemler eğitildikten sonra gerçek hayatta kullanıma alındığında artık öğrenme işlemi gerçekleşmemektedir. Sistemin öğrenmesi gereken yeni bilgiler söz konusu olduğunda sistem kullanımdan çıkarılmakta ve çevrimdışı olarak yeniden eğitilmektedir. Eğitim tamamlanınca sistem tekrar kullanıma alınmaktadır (Öztemel, 2012).

Bütün örnekler eğitim başlamadan önce mevcut olsa bile çevrimiçi/uyarlanabilir eğitim uygulanabilir; oysa tüm örnekler mevcut değilse, uygun olmayan bir teknik kullanılamaz (Dreyfus, 2005).

Her iki yöntem de yaygın olarak kullanılmaktadır ve her iki yöntem de avantaj ve dezavantajlara sahiptir. Her durumda, eğitim, makul derecede düşük bir hata elde edilene veya eğitim için ayrılan enbüyük ardıştırma sayısı aşılanaya kadar devam eder. Bazı yazarlar, ardıştırmayı tek bir veri ögesinin sunumunu belirtmek için kullansa da, literatürde bu terim genellikle bir döneme işaret eder. Bazı uygulamalar için girdi-çıkı desenlerini çevrimiçi olarak sunulmaktadır, bu nedenle de çevrimdışı öğrenme mümkün değildir. Bu insan öğrenmesinin bir özelliğidir; ömür boyu tecrübe ve uygun kararlar bir kerede verilemez. Ancak, çevrimiçi eğitim, çevrimdışı eğitimden daha pahalıdır; çünkü her örnek sunumundan sonra ağırlıklar değiştirilmelidir (Mehrotra vd., 1997).

4.7. YSA Öğrenme Algoritmaları

4.7.1. Temel öğrenme kuralları

Öğrenme, tek bir nöronun bireysel yeteneği değildir. Bütün sinir ağının ortak bir süreci ve bir eğitim süreci sonucudur. Bağlantı ağırlık matrisi W , genel bir model anlamını taşır. "Bilgiyi" bütünüyle temsil eder. Öğrenmenin insan beyninde nasıl gerçekleştiği tam olarak bilinmemektedir. Fakat öğrenme (gözetim altında veya denetimsiz), yapay bir sinir ağında gerçekleştirilebilir. Keşfedilen ve uygulanan bazı genetik öğrenme yasaları vardır (Kasabov, 1996). Temel öğrenme kuralları şunlardır (Hagan vd., 2014; Haykin, 2008; Ataseven, 2013):

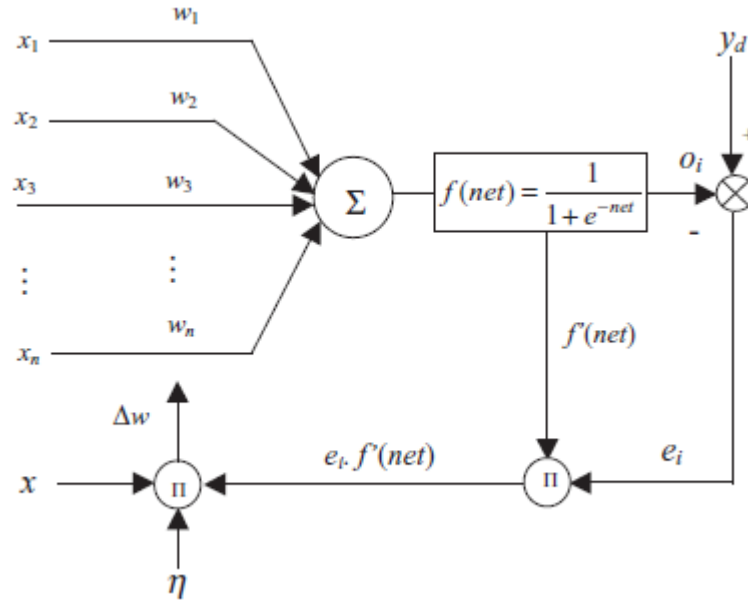
1. Hebb Kuralı
2. Delta Kuralı
3. Rekabetçi Öğrenme Kuralı
4. Boltzmann Kuralı
5. Algılayıcı (Perceptron) Öğrenme Kuralı

ÇKA ağının öğrenme kuralı en küçük kareler yöntemine dayalı Delta Öğrenme Kuralının geliştirilmiş halidir. Bu yüzden öğrenme kuralına "Genelleştirilmiş Delta Kuralı" da denmektedir (Öztemel, 2003). Bu nedenle bu bölümde Delta Kuralı üzerinde durulacaktır.

Delta Kuralı

Bu kural, Hebb kuralının bir varyasyonudur ve ağın istenen çıktı ile gerçek çıktısı arasındaki farkı (delta) azaltmak için girdi bağlantılarının ağırlıklarını sürekli olarak değiştirme fikrine dayanmaktadır. Ağın ağırlıklarını, ağın ortalama kareli hatasını en aza indirmek için değiştirir. Çıktı katmanındaki delta hatası, transfer fonksiyonunun türevi ile dönüştürülür ve bu hata bir kerede bir katman önceki katmanlara geri gönderilir. Ağ hatalarını geri iletme süreci ilk katmana ulaşana kadar devam eder. Delta kuralı kullanırken, girdi veri setinin iyi rassallaştırılmasını sağlamak önemlidir. Eğitim verileri setinin düzenli veya yapılandırılmış bir sunumu, istenen doğruluğa yakınlaşamayan bir ağa, dolayısıyla ağın problemi öğrenememesine yol açabilir (Siddique ve Adeli, 2013).

Delta öğrenme süreci Şekil 4.9 'da gösterilmektedir. Burada x_n girdileri, w_n ağırlıkları, \sum toplam fonksiyonu, $f(\text{net})$ aktivasyon fonksiyonunu, o_i gerçek çıktı, y_d istenilen çıktı, η öğrenme oranı (sabitini), e_i hatayı, $f'(\text{net})$ aktivasyon fonksiyonunun türevini temsil etmektedir.



Şekil 4.9. Delta öğrenme kuralı (Siddique ve Adeli, 2013).

4.7.2. Öğrenme algoritmaları

Çok katmanlı YSA'da en hızlı iniş algoritması olarak geliştirilmiş geri yayılım algoritması kullanılmaktadır (Özalp ve Anagün, 2001). Bu bölümde genel olarak geri yayılım algoritmaları üzerinde durulacaktır.

4.7.2.1. Geri yayılım algoritması

Geri yayılım algoritması, ileri beslemeli çok katmanlı sinir ağlarında öğrenme algoritması olarak yaygın şekilde kullanılan matematiksel bir araçtır (Yadav vd., 2015).

Standart geri yayılım, bir eğim iniş (gradient descent) algoritmasıdır. 'Geri yayılım' terimi, eğrisinin doğrusal olmayan çok oyunculu ağlar için hesaplanma biçimini belirtir (Siddique ve Adeli, 2013).

Geriye yayılım öğrenme prosedürünü uygulamak için şunlar gereklidir (Yadav vd., 2015):

- (i) Normalleştirilmiş eğitim desenleri seti, yani örnek veya veri, girdileri ve bunlara karşılık gelen hedefleri.
- (ii) Öğrenme oranı için değer.

- (iii) Algoritmayı sonlandıran ölçüt.
- (iv) Ağırlıkların güncellenmesi için yöntem, yani ağırlık güncelleme kuralları ve kural güncellemesi için farklı ölçütler.
- (v) Genellikle sigmoid aktivasyonu, doğrusal olmayan aktivasyon için kullanıcı tarafından tercih edilir.
- (vi) Başlangıç ağırlık değerleri (genellikle -0.5 ile 0.5 arasında rastsal sayılar).

Bazı geri yayılım algoritmaları şunlardır (Siddique ve Adeli, 2013; Rabunal ve Dorado, 2005; Reidmiller ve Braun, 1993; Mcfall, 2006; Yadav vd., 2015; Hristev, 1998; Priddy ve Keller, 2005):

1. Esnek Geri Yayılım Algoritması (Resilient Back Propagation Algorithm)
2. Gradyan Azalma Algoritması(Gradient Descent Algorithm)
3. Levenberg -Marquardt Yöntemi
4. Hızlı Yayılım Algoritması (Quick Propagation Algorithm)
5. Bayesyen Düzeltme (Bayesian Regularization) Geri Yayılım Algoritması

Bu öğrenme algoritmalarının yanısıra Genetik Algoritmalar (Montana ve Davis, 1989; Sexton ve Gupta, 2000: Yadav vd.'den (2015)) (Yadav vd., 2015) gibi bazı sezgisel algoritmalarda öğrenme algoritması olarak kullanılmaktadır.

4.7.2.2. Levenberg-Marquardt Geri Yayılım Algoritması

Levenberg-Marquardt (LM) algoritması, ikinci dereceden türevlerin kullanımına dayanan doğrusal olmayan bir eniyileme algoritmasıdır (Levenberg, 1944; Marquardt, 1963: Priddy ve Keller'den (2005)). Martin Hagan ve Mohammad Menhaj tarafından ileri beslemeli sinir ağı eğitiminde kullanılmak üzere uyarlanmıştır (Hagan, 1994: Priddy ve Keller'den (2005)). Geri yayılımda olduğu gibi, ağırlık değişimlerini hesaplar. Ancak, geri yayılımdan daha kısıtlıdır. Quasi-Newton yöntemleri gibi, LM algoritması için bellek gereksinimleri, ağırlık sayısının karesinin bir fonksiyonu olarak ölçülür; bu nedenle, genellikle birkaç yüz ağırlıktaki küçük ağlarla sınırlandırılmıştır. Ayrıca, yalnızca toplam karesel hata fonksiyonlarıyla çalışır; bu nedenle tahmin (yani, regresyon) uygulamaları için sıklıkla kullanılır (Masters, 1995; Bishop, 1995: Priddy ve Keller'den (2005)).

LM algoritması, geri yayılımda ve Newton yönteminde bulunan Gradient Azalış özelliklerinin bir birleşimidir (Priddy ve Keller, 2005). Bu algoritma "karelerin toplamı" hata

fonksiyonu için özel olarak tasarlanmıştır (Hristev, 1998). Modellenmekte olan temel işlevin doğrusal olduğunu ve minimum hatanın bir adımda bulunabileceğini varsayar. Bu tek adımı gerçekleştirmek için ağırlık değişimini hesaplar. Yeni hatanın daha düşük olup olmadığını belirlemek için ağı bu yeni ağırlıklarla test eder. Ağırlıklardaki bir değişiklik ancak hatayı düzeltirse kabul edilir. Hata azaltıldığında, ağırlık değişimi kabul edilir ve doğrusal varsayım bir μ kontrol parametresinin azaltılmasıyla takviye edilir. Hata arttığında, ağırlık değişimi reddedilir ve geri yayılım gibi doğrusal varsayımı azaltmak için kontrol parametresini arttırarak bir gradient azalış uygulanır. Bu şekilde, LM algoritması Newton ve Gradient Azalış süreci arasında bir uzlaşmadır. Enküçük yakınında doğrusal varsayım yaklaşık olarak doğrudur, bu nedenle LM algoritması bu ikinci derece Newton benzeri özellik kullanılarak çok hızlı ilerleme kaydeder. Enküçük değer dışında, doğrusal varsayım sıklıkla kötüdür, ancak hata artmadığı zaman Gradyan Azalma kullandığından hala enküçük bir hata ile birleşecektir. İşlem, arzu edilen hata veya maksimum yineleme sayısına ulaşılan kadar tekrarlanır (Priddy ve Keller, 2005).

4.7.2.3. Bayesyen Düzeltme (Bayesian Regularization) Geri Yayılım Algoritması

Bayesyen Düzeltme, ağırlıkları ve biası LM optimizasyonuna dayanarak güncelleyen bir öğrenme algoritmasıdır (Foresee ve Hagan, 1997; MacKay, 1992). Kare hatalardan ve ağırlıklardan oluşan bir kombinasyonu en aza indirir ve daha sonra genelleştiren bir ağı üretmek için doğru kombinasyonu belirler (Pan vd., 2013). BR ağı ağırlıklarını eğitim amaç fonksiyonuna verir (Yue vd., 2011).

Levenberg-Marquardt Algoritması içinde ağı genellemesinin iyileştirilmesi için bir kural olarak normalleştirme (regularization) uygulamaktadır. Normalleştirme, performans fonksiyonunda değişiklik gerektirir. Bunun için performans fonksiyonu, hataların karelerinin toplamıdır ve ağı ağırlıklarının ve biasların karelerinin toplamından oluşan bir terimi içerecek şekilde değiştirilir (Tiwari vd., 2013).

Bayesyen Düzeltme Algoritması ile Yapay sinir ağıları standart geri yayılım ağılarından daha sağlamdır ve uzun çapraz doğrulama ihtiyacını azaltabilir veya ortadan kaldırabilir (Cartwright, 2009).

4.8. YSA Modelleri

Yapay Sinir Ağları modelleri Çizelge 4.2’den de görülebileceği gibi denetimli, denetimsiz ve melez ağlar olmak üzere üç ana gruba ayrılabilir. Her mimariye uygun öğrenme kuralı, öğrenme algoritması ve yerine getirdikleri görevler değişiklik göstermektedir. Öne çıkan öğrenme modelleri Perceptron (Fausett, 1994; Mehrotra vd., 1997), Çok Katmanlı İleri Beslemeli Ağ (Mehrotra vd., 1997; Karayiannis ve Venetsanopoulos, 1993; Priddy ve Keller, 2005) , Hopfield Ağı (Kasabov, 1996; Pham ve Karaboga, 2000) ve Kendini Düzenleyen Haritalar (SOM) (Self-Organizing Maps) (Kohonen vd., 1984; Ruan, 1997)’ dur.

Çizelge 4.2. Bilinen öğrenme algoritmaları (Jain ve Mao, 1996).


Paradigma	Öğrenme Kuralı	Mimari	Öğrenme Algoritması	Görev
Denetimli	Hata-düzeltilme	Tek veya çok katmanlı perceptron	Perceptron öğrenme algoritmaları Geri yayımlı Adaline (Adaptif Doğrusal Birleştirici) ve Madaline (Çoklu Adaptif Doğrusal Birleştirici)	Desen sınıflandırma Fonksiyon yaklaşımı Tahmin, kontrol
	Boltzmann	Geri beslemeli	Boltzmann öğrenme algoritması	Desen sınıflandırma
	Hebbian	Çok katmanlı ileri beslemeli	Doğrusal diskriminant analizi	Veri analizi Desen sınıflandırma
	Rekabetçi	Rekabetçi	Öğrenme vektör niceleme	Sınıf içinde kategorizasyon Veri sıkıştırma
		ART (Adaptif Resonans Teorisi) ağı	ARTMap	Desen sınıflandırma Sınıf içinde kategorizasyon
Denetimsiz	Hata-düzeltilme	Çok katmanlı ileri beslemeli	Sammon’s projection	Veri analizi
	Hebbian	İleri beslemeli veya rekabetçi Hopfield Ağı	Temel bileşenler analizi İlişkisel hafıza öğrenme	Veri analizi Veri sıkıştırma İlişkisel hafıza
	Rekabetçi	Rekabetçi Kohonen’s SOM	Vektör niceleme Kohonen’s SOM	Kategorizasyon Veri sıkıştırma Kategorizasyon Veri sıkıştırma
Melez	Hata-düzeltilme ve rekabetçi	ART ağları RBF (Radyal Tabanlı Fonksiyon) ağı	ART1, ART2 RBF öğrenme algoritması	Kategorizasyon Desen sınıflandırma Fonksiyon yaklaşımı Tahmin, kontrol

Çok Katmanlı İleri Beslemeli Ağ

Perceptronlar ve diğer tek katmanlı ağlar, yeteneklerinde ciddi anlamda sınırlıdır. Doğrusal olmayan düğüm fonksiyonlarına sahip çok katmanlı ağlar, bu sınırlamaları aşabilir ve birçok uygulama için kullanılabilirler (Mehrotra vd., 1997). Çok katmanlı bir sinir ağı, girdi katmanı ile çıktı katmanı arasında gizli birimlerden oluşan bir veya daha fazla katman içerir. Gizli bir birim bir girdiye, bir çıktı birimine veya başka bir katmanın ait gizli bir birime bağlanabilir (Karayiannis ve Venetsanopoulos, 1993).

ÇKA Modeli Rumelhart ve arkadaşları tarafından geliştirilmiştir. Bu modele hata yayma modeli veya geri yayılım modeli (backpropagation network) de denilmektedir. ÇKA modelinde geriye yayılım algoritması kullanılmaktadır. Bu algoritma ara katman içeren yapay sinir ağlarında kullanılan güçlü bir öğrenme algoritmasıdır. ÇKA ağının öğrenme kuralı en küçük kareler yöntemine dayalı Delta Öğrenme Kuralının genelleştirilmiş halidir. Bu yüzden öğrenme kuralına “Genelleştirilmiş Delta Kuralı” da denmektedir (Öztemel, 2003). Bu ağ yapısında “Öğretmenli Öğrenme” yöntemi kullanılır. Öğretmenli öğrenmede hedef çıktı değerleriyle ilişkilendirilen her bir vektör, ağın öğrenmesi için ağa sunulur. Ağırlıklar, belirtilen öğrenme kuralına dayanarak düzeltilir (Hamid ve Iqbal, 2004).

Basit bir ileri beslemeli sinir ağının açıklaması Şekil 4.10'da verilmiştir. Şeklin sol kısmı, nöronların ilk katmanına, ardından nöronların birbirine bağlı katmanlarına ve son olarak nihai nöron katmanının çıktılara ait girdilerdir. Her bir katmanın ağıdaki bir sonraki katmanı doğrudan beslediği ve girdileri ağ üzerinden ilerlettiği, bu ağ mimarisinin ileri beslemeli ağ etiketini aldığı unutulmamalıdır. Nöronların transfer fonksiyonları, ağın ileri besleme davranışını etkilemez. Sigmoid transfer işlevlerine sahip birçok ileri beslemeli ağlar bulunmaktadır, ancak ileri beslemeli ağlardaki nöronlar, tasarımcının kullanmak istediği herhangi bir aktarım fonksiyonu olabilir. Buna ek olarak, birinci katmandaki bir nöron ikinci katmanın yanı sıra üçüncü katmana da bir nöron verebilir. İleri beslemeli ağlar, ağıdaki bir ya da daha fazla nörona ya da katmana bireysel nöronların çıktılarını gönderir. Bir katmanın nöronlarındaki çıktıları kendinden önceki katmanlarının girdilerine veya kendi katmanlarındaki diğer nöronlarına geri gönderen ağlara tekrarlayan ağlar denir. Sinir ağı topolojileri mimari, fonksiyon ve davranış farklılıklarıyla geniş çapta değişebilir (Priddy ve Keller, 2005).



Şekil 4.10. Çok katmanlı ileri beslemeli sinir ağı (Priddy ve Keller, 2005).

İstenen girdi-çıktı eşleştirmesini doğru gerçekleştirmek için bir nöron veya ağ ağırlıkları değiştirme işlemine, bir sinir ağı topluluğunda öğrenme denir. Sinir ağı çalışmalarını eğitmek için pek çok yöntem olmakla birlikte tüm öğrenme çeşitleri birbirine bağlı nöronlar arasındaki ağırlıkları ayarlamaya dayanmaktadır. Belirli bir ağ mimarisi seçildikten sonra tasarımcı, istenen ağ davranışını etkilemek için hangi ağırlığın değiştirileceğini belirlemelidir (Priddy ve Keller, 2005).

5. TAHMİN PERFORMANSI ÖLÇME TEKNİKLERİ

Uygulamada, hatasız bir tahmin elde etmek pek mümkün olmamaktadır. Bunun yerine, çeşitli tahminlerin (hepsi alt optimal) karşılaştırıldığı, sonrasında muhtemelen birleştirildiği durumlar ortaya çıkar. Çok iyi tahminler için bile gerçek ve öngörülen değerler çok farklı olabilir. Örnek vermek gerekirse, sıfır ortalamalı bir beyaz gürültü süreci için doğrusal en küçük kareler tahmini basitçe 0'dır, -kuadratik kayıp altında daha iyi bir doğrusal tahmin bulunmamaktadır (Diebold, 2006).

Performans genellikle aşağıdaki dört ana hedefi gerçekleştirmek için ölçülmektedir (Moon, 2013):

1. Tahmin sürecinin iyileşip iyileşmediğini görmek için izleme,
2. Belirli tahmin teknikleri veya araçlarıyla ilgili sorunları teşhis etme,
3. Stok kararlarında yardımcı olmak için talep değişkenliğinin ölçülmesi,
4. Mükemmel tahmini bulmayı kolaylaştırmak için bireysel performansı takip etme.

5.1. Hata Büyüklüğü Doğruluğu

Doğruluk tahmini için en iyi bilinen kavram 'hata büyüklüğü doğruluğu' dur ve belirli bir tahmin modeli ile ilişkili tahmini hata ile ilgilidir. Denklem 5.1'deki gibi tanımlanır (Frechtling, 2001):

$$e_t = A_t - F_t \quad (5.1)$$

burada

t = bir ay, üç ay veya bir yıl gibi belirli bir zaman periyodu

e_t = t . zaman periyodundaki tahmin hatası

A_t = t . zaman periyodundaki tahmin edilen değişkenin gerçek değeri

F_t = t . zaman periyodundaki tahmin değeri.

t zamanındaki gerçek değer, tahmin değerinden büyükse, tahmin hatası pozitifdir. Tahmin değerinden düşükse, tahmin hatası negatif olur (Frechtling, 2001).

Bir tahmin modelinin hata büyüklüğü doğruluğunu özetlemenin birkaç yolu bulunmaktadır. Bunlardan bazıları mutlak hata ölçümlerini hesaplar ve bu nedenle modelin test

edildiği birimlere ve zaman periyoduna tabidir. Farklı modeller arasında yorumlama ve karşılaştırma yapmak çoğu kez zordur (Frechtling, 2001).

5.2. Ortalama Mutlak Hata (MAE)

Sıklıkla kullanılan diğer bir doğruluk ölçüsü de ortalama hatadır (Chase Jr., 2009). Ortalama mutlak hata (MAE) genellikle ortalama mutlak sapma veya ortalama mutlak hata olarak adlandırılır. Diğer olasılıklar da mümkündür. Her durumda, MAE, tahmin hatalarının mutlak değerini aldıktan sonra bu hataların ortalamasıdır (Kacapyr, 1996). Gerçek formülasyon Denklem 5.2'deki gibi yazılabilir (Chase Jr., 2009):

$$MAE = \frac{1}{T} \sum_{t=1}^T |A_t - F_t| \quad (5.2)$$

burada

t = zaman periyodu

T = zaman periyodlarının sayısı

A_t = t zaman periyodundaki tahmin edilen değişkenin gerçek değeri

F_t = t zaman periyodundaki tahmin

Ortalama Mutlak Hata (MAE), ölçüm değerleri ile model tahminleri arasındaki mutlak hatayı belirlemek amacıyla kullanılmaktadır. MAE değeri sıfıra ne kadar yakın olursa modelinin tahmin yeteneği o kadar iyi demektir (Eren ve Eyüpoğlu, 2011).

5.3. Hata Kareleri Ortalaması (MSE)

Hata Kareleri Ortalaması (MSE), tahmin hatalarının karelerinin toplamının terim sayısına bölünmesiyle hesaplanır. En düşük MSE'ye sahip modelin en iyi olduğu varsayılmıştır (Lewis, 1997). MSE, Denklem 5.3'deki gibi hesaplanır.

$$MSE = \frac{1}{T} \sum_{t=1}^T e^2 \quad (5.3)$$

MSE genellikle örnek kanıt özelliklerini özetlemek için tamamen tanımlayıcı bir istatistik olarak kullanılır (Holden vd., 1990).

5.4. Hata Kareleri Ortalamasının Kökü (RMSE)

Pozitif olanları dengeleyerek negatif hatalarla mücadele etmenin diğer bir yolu ise onları kare haline getirmektir. Negatif tahmin hatalarının karesi alındığında pozitif olurlar. Bu kareleştirilmiş değerlerin birlikte ortalaması alınır ve sonra ortalamayı orijinal boyutuna yeniden ölçeklendirmek için karekök alınır. Bu istatistiğe Hata Kareleri Ortalamasının Kökü (RMSE) denilmektedir. Başka yerlerde ise, ortalama kare hataların sapması veya kök ortalama karesel hata da denilmektedir. Matematiksel terimlerle Denklem 5.4'deki gibidir (Kacapyr, 1996).

$$RMSE = \sqrt{\frac{\sum e_t^2}{T}} \quad (5.4)$$

Hata büyüklüğü doğruluğunun tüm zaman serileri ve kantitatif tahmin yöntemleri için kullanışlı diğer bir ölçüsü de ortalama kare hataları yüzdesi kökü veya RMSPE' dir. Denklem 5.5 kullanılarak hesaplanır (Frechtling, 2001).

$$RMSPE = \sqrt{\frac{(e_t)^2}{A_t}} * 100 \quad (5.5)$$

burada,

T = toplam dönem sayısı,

e_t = t. dönem tahmin hatası,

A_t = t. dönem tahmin edilecek değişkenin gerçek değeridir.

Bu ölçü, aynı zamanda, ortalama hatayı yüzdelere açısından hesaplar ve tarihsel veri serilerindeki gerçek değişim oranları ile karşılaştırılabilir. Bununla birlikte, daha büyük hataları küçük olanlardan daha fazla cezalandırır. Bu durum, tahmin modelinizde küçük hatalarla devam edebiliyor fakat birkaç büyük hatayı kabul edemiyorsanız önemlidir. Büyük hataları en çok engelleyen model olarak tahmin hatasının RMSPE ölçüsü seçilebilir (Frechtling, 2001).

5.5. Ortalama Mutlak Yüzde Hata (MAPE)

Diğer bir tahmin doğruluğu ölçüsü olan ortalama mutlak yüzde hata (MAPE) Denklem 5.6'daki gibi tanımlanır (Holden vd., 1990):

$$MAPE = \frac{100}{T} \sum_{t=1}^T \left| \frac{A_t - F_t}{A_t} \right| \quad (5.6)$$

MAPE'yi MSE ve MAE'den ayıran fark, büyük hatalara fazladan ağırlık vermemesidir. Dolayısıyla doğrusal (orantılı hatalarla) kayıp fonksiyonuna karşılık gelir. MAPE üzerinde bir değişiklik ile ortanca mutlak yüzde hata (MdAPE) elde edilir. Bu basit şekliyle, mutlak yüzde hataların medyan değeridir ve bu hataların çarpık bir dağılıma sahip olması tercih edilir, böylece ortalama birkaç uç değerle çarpılır (Holden vd., 1990).

5.6. Theil U İstatistiği

Theil U-İstatistiği, aynı veri serisi için bir tahmin modelinin doğruluğunun nesnel bir ölçüsünü Naive 1 modeline göre sağlar (Makridakis, Wheelwright ve Hyndham, 1998). Biçimsel olarak (Makridakis vd., 1998: Frechtling'den (2001)),

$$U = \sqrt{\frac{\sum_{t=1}^{T-1} \left(\frac{F_{t+1} - A_{t+1}}{A_t} \right)^2}{\sum_{t=1}^{T-1} \left(\frac{A_{t+1} - A_t}{A_t} \right)^2}} \quad (5.7)$$

burada,

F_t = t. dönem tahmin değeri,

A_t = t. dönem tahmin edilecek değişkenin gerçek değeridir.

U istatistiği aralıklarının yorumu aşağıdaki gibidir (Frechtling, 2001):

$U = 1$: Naive 1, değerlendirilmekte olan tahmin modeli kadar iyidir

$U < 1$: Tahmin modeli Naive 1 yaklaşımından daha iyidir ve U istatistiği küçüldükçe bu üstünlük artar

$U > 1$: Naive 1 modeli, incelenen tahmini modelden daha doğru bir veri serisi tahmini ürettiğinden, tahmin modelini kullanmak için bir neden yoktur.

6. BIST 30'DA YER ALAN HİSSE SENETLERİNİN AYLIK KAPANIŞ FİYATI TAHMİNLERİ İÇİN PORTFÖY OPTİMİZASYONU TEMELLİ KARŞILAŞTIRMA UYGULAMASI

Uygulamada, BIST 30'da işlem gören ve 2008 - 2014 yılları arasında verileri bulunan 26 farklı hisse senedine ait aylık kapanış fiyatları kullanılmıştır. Veriler, İMKB'nin resmi internet sitesinden resmi izinle alınmıştır (www.datastore.borsaistanbul.com).

Uygulama adımları aşağıda verilmiştir:

1. Veri Analizi

IBM SPSS Statistics 24 programı aracılığıyla 26 adet hisse senedinin 2008-2013 yılları arasındaki aylık kapanış değerlerinin betimsel istatistikleri oluşturulmuş ve normal dağılım testleri yapılmıştır.

2. Hisse Senetlerinin Kapanış Fiyatlarının Tahminlenmesi

a) Yapay Sinir Ağları ile tahminleme

Her hisse senedi için Çok Katmanlı Yapay Sinir Ağları ile tahminleme yapılmıştır. Tahmin çalışmalarında MATLAB r2015a yazılımının Yapay Sinir Ağları aracı kullanılmıştır. Tahminleme yapılırken değiştirilen parametreler; saklı katmandaki nöron sayısı, zaman dilimi, girdi değişkeni sayısı ve öğrenme algoritmasıdır. Tahminleme, veriler açısından 3 farklı zaman diliminde yapılarak karşılaştırılmıştır.

- 1) 2008-2011 dönemine ait aylık kapanış fiyatları kullanılarak 2012 yılına ait 12 aylık kapanış fiyatları,
- 2) 2008-2012 dönemine ait aylık kapanış fiyatları kullanılarak 2013 yılına ait 12 aylık kapanış fiyatları,
- 3) Son olarak 2008-2013 dönemine ait aylık kapanış fiyatları kullanılarak 2014 yılına ait 12 aylık kapanış fiyatları tahmin edilmiştir.

Tahminler yapılırken sinir ağı için öğrenme algoritması olarak Levenberg-Marquardt Geri Yayılım Algoritması kullanılmıştır. Bu öğrenme algoritması literatürde var olan çalışmalar içerisinde en fazla kullanılan algoritma olduğu için tercih edilmiştir. Genel olarak, bu metod yavaş yakınsama probleminden etkilenmez (Ataseven, 2013). Tahminlerin sonuçlarından hareketle en iyi tahminleme zaman dilimi ve en uygun girdi değişkeni sayısı bulunarak bu tahminler Bayesyen Düzeltme Geri Yayılım Algoritması ile karşılaştırılmıştır. Tahminler karşılaştırılırken MAE, MSE, MAPE hata performans değerlendirmeleri kullanılmıştır. Bu

öğrenme algoritması “aşırı uyum” ihtimalini azaltarak ağın genelleme (tahmin) yeteneğinin yüksek kalmasını sağlamaktadır. Bu sebeple YSA’yla tahmin problemlerinde son zamanlarda yaygın şekilde kullanılmaktadır (Çalışkan ve Deniz, 2015).

b) Zaman Serileri Analizi

2008-2013 dönemine ait aylık kapanış fiyatlarından hareketle Basit Ortalama Yöntemi, Hareketli Ortalamalar Yöntemi, Üstel Düzeltme Yöntemi ve Trend Analizi Yöntemi kullanılarak 2014 yılı 12 aylık kapanış fiyatları tahmin edilip Yapay Sinir Ağı Sonuçları ile karşılaştırılmıştır. Zaman serileri analizi ile tahminler, Microsoft Excel programında tahmin yöntemlerinin gerektirdiği formüller kullanılarak yapılmıştır.

3. Tahmin hatalarının karşılaştırılması

Yapay Sinir Ağları için kullanılan veri seti normalize edilmiş fakat karşılaştırılan diğer yöntemlerde tahmin yapılırken normalizasyona gerek duyulmamıştır. Bu yüzden karşılaştırmaların sağlıklı olması açısından yüzdesel olarak hesaplanan MAPE ölçümü karşılaştırma ölçütü olarak kullanılmıştır.

4. Tahminlerin birleşimi için farklı modeller temelli Portföy Optimizasyonu

Yapay sinir ağları ile elde edilen tahminler ve zaman serileri analizi ile yapılan tahminlerden elde edilen iyi sonuçlardan hareketle ilgili model parametreleri hesaplanmış olup, daha sonra hesaplanan parametrelere dayalı olarak farklı beklenen getiri düzeylerinde farklı portföy optimizasyonu modelleri oluşturulmuştur. Portföy Eniyileme Modelleri Lingo 11.0 eniyileme paket programı kullanılarak çözülmüştür.

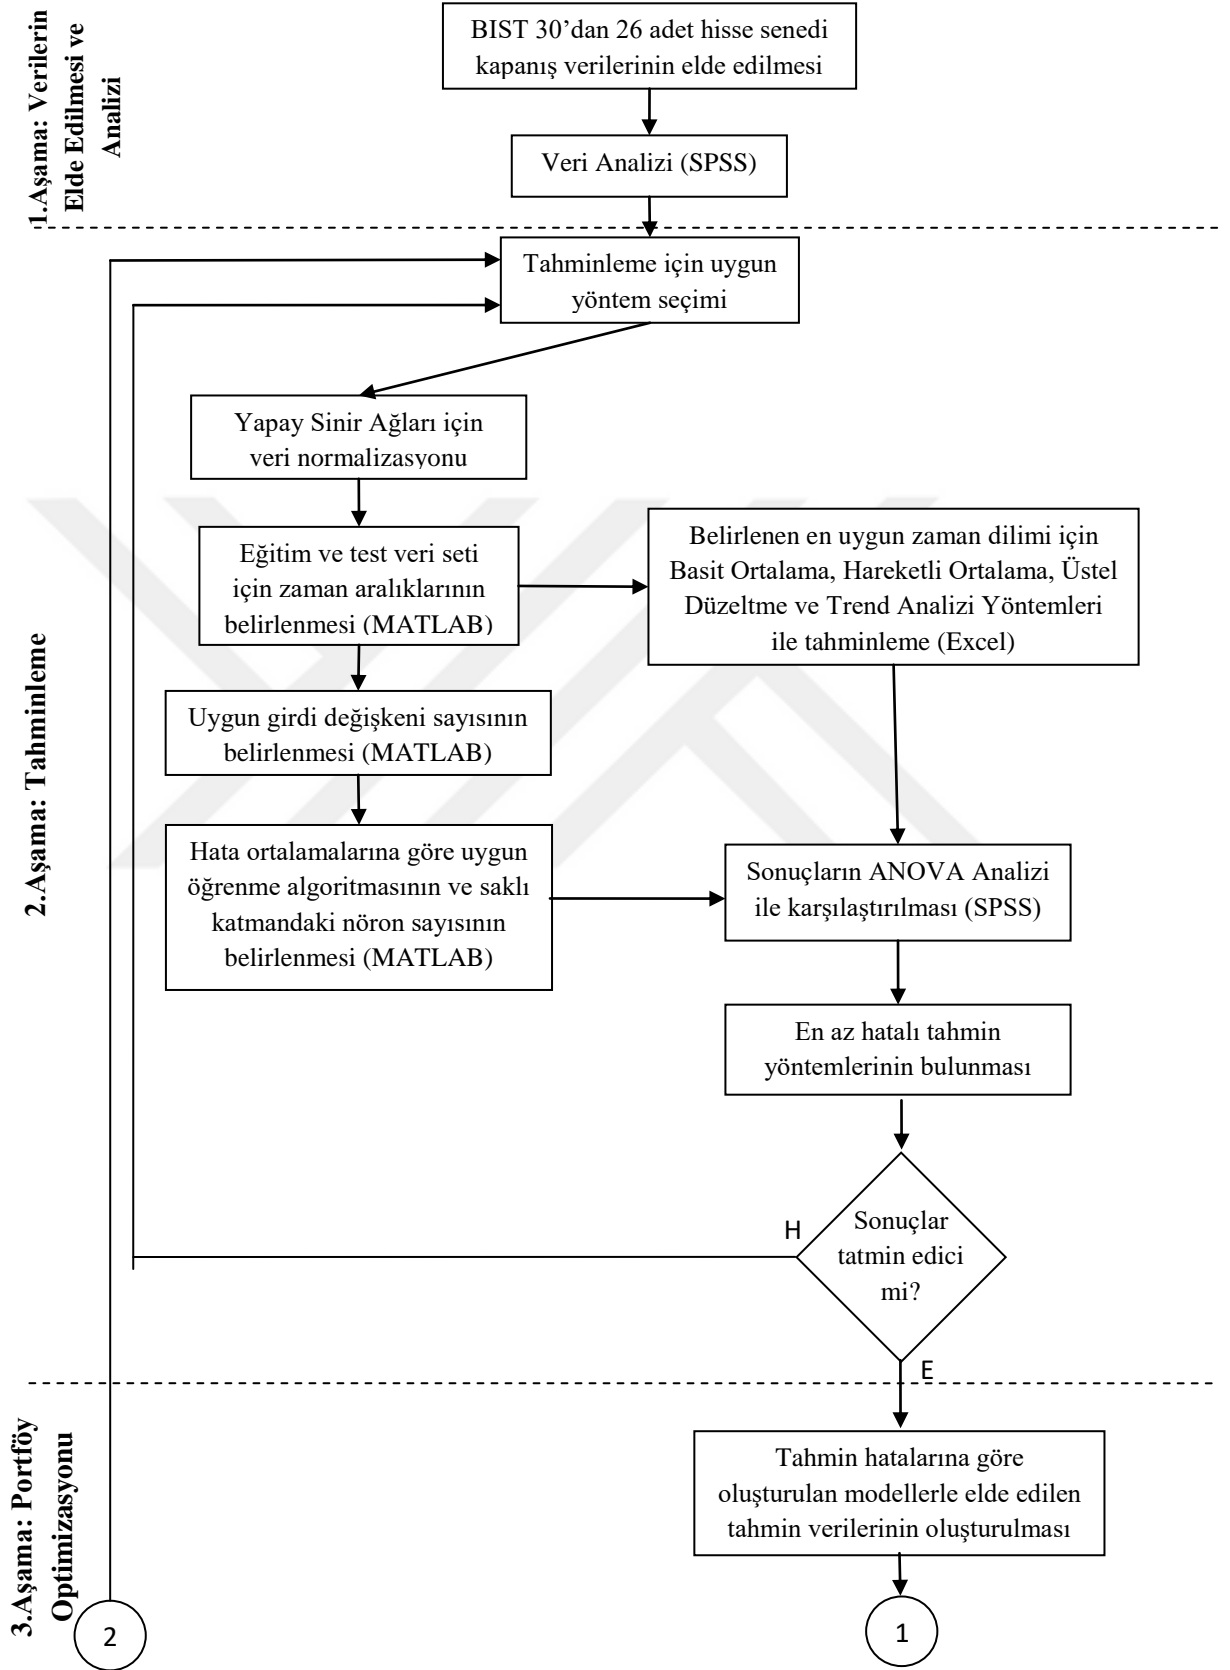
5. Pareto yüzey temelli karşılaştırma

Önerilen bütün modelleri içeren getiri aralığı belirlenerek bu aralık eşit dilimlere ayrılmış ve her bir dilime karşı gelen getiriler için ortalama-varyans modeli Lingo 11 programı ile çözülmüş ve Pareto yüzeyler elde edilmiştir.

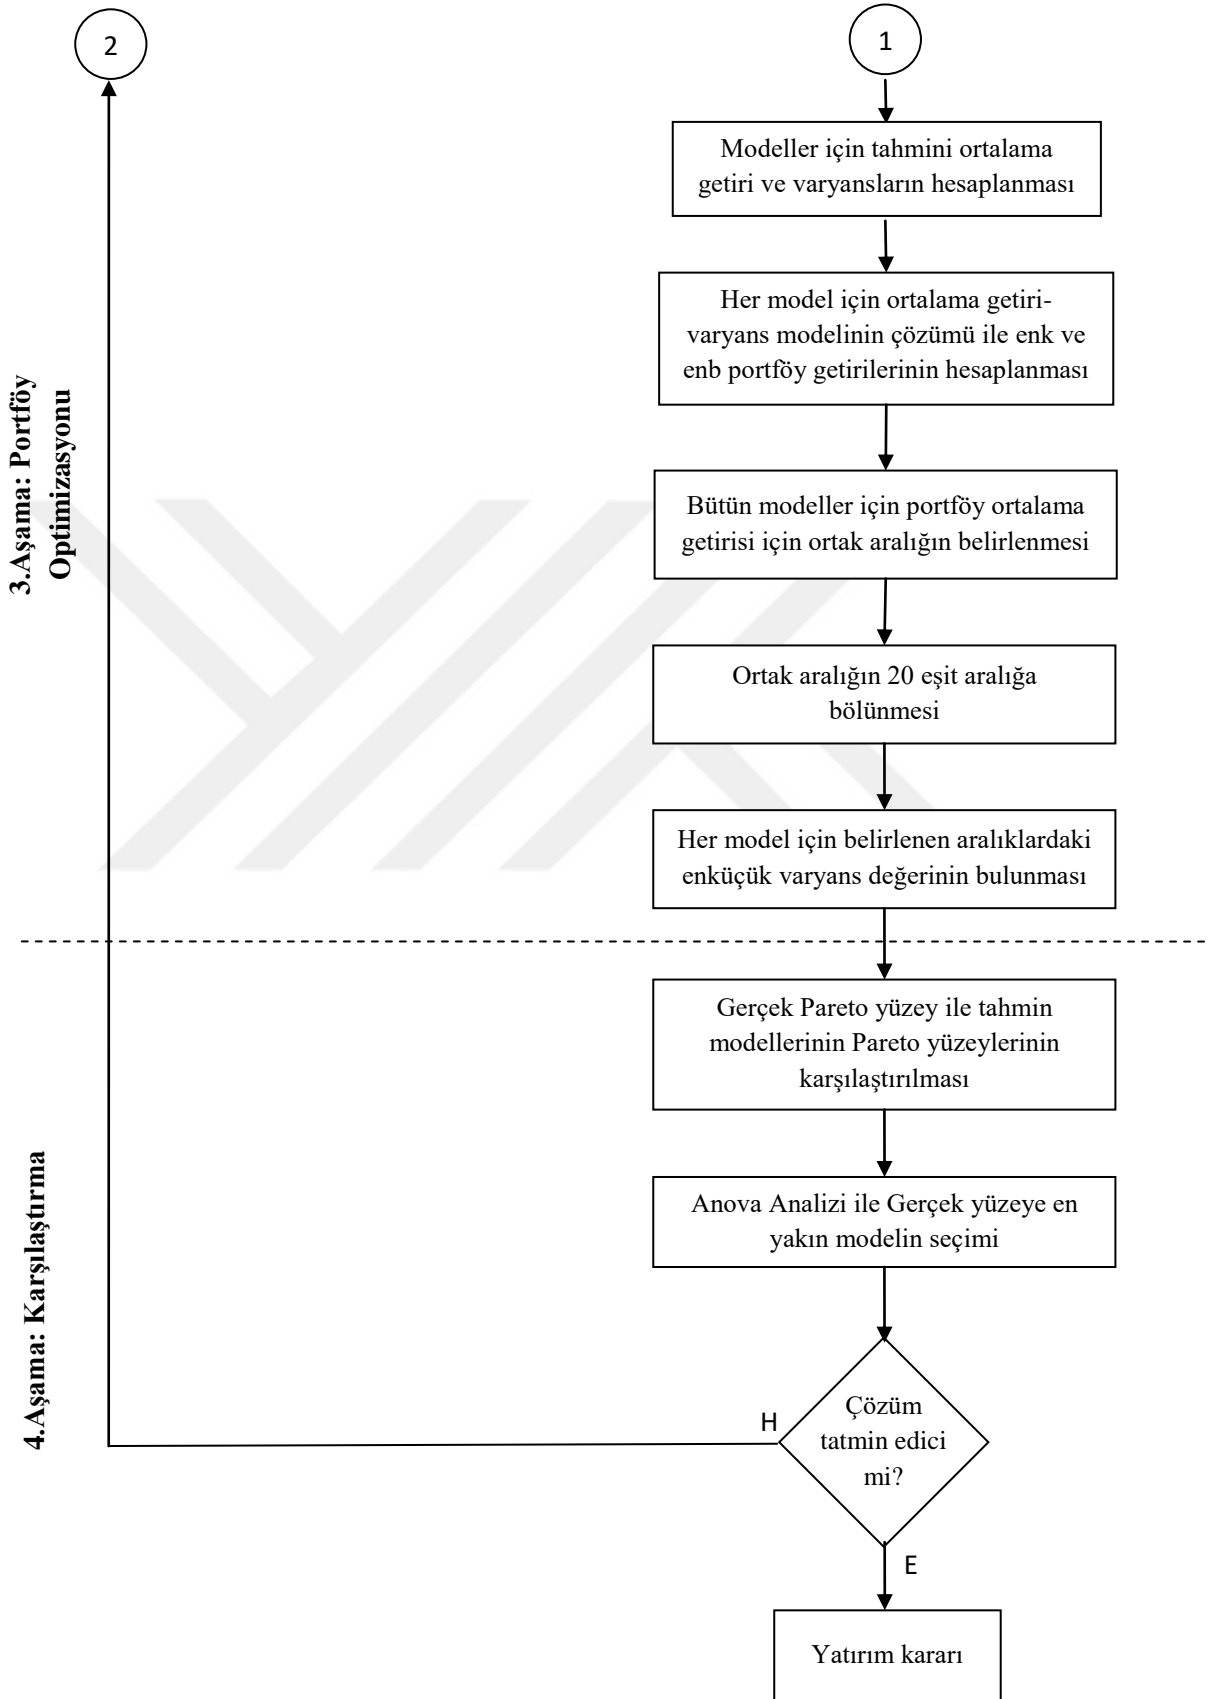
6. Etkin Portföy Optimizasyonu modelinin seçimi

Önerilen modellerle elde edilen tahmini getirilere göre belirlenmiş olan Pareto yüzeyler, gerçek verilerle oluşturulmuş Pareto yüzeyle Varyans Analizi ve Tamhane Testi ile karşılaştırılmıştır. Etkin modeller belirlenmiştir.

Uygulamaya ait akış şeması Şekil 6.1’de verilmektedir.



Şekil 6.1. Uygulama akış şeması.



Şekil 6.1. Uygulama akış şeması (devamı).

6.1. Veri Analizi

Analizlere, serilerin birbirinden farklı olup olmadıklarını belirlemek amacıyla, 26 adet hisse senedinin 2008-2013 yılları arasındaki aylık kapanış değerlerinin betimsel istatistiklerinin oluşturulması ve normal dağılım testlerinin yapılmasıyla başlanmıştır. Analizlerde IBM SPSS Statistics 24 programı kullanılmıştır. Program aracılığıyla tüm değerlere Shapiro-Wilk-W testi yapılmıştır. 26 adet hisse senedinin 6 yıllık dönemdeki aylık kapanış değerlerinin dağılımına ilişkin istatistikler ve normal dağılım testi sonuçları sırasıyla Çizelge 6.1’de yer almaktadır. Hisse senetlerinin istatistikleri incelendiğinde farklı niteliklere sahip oldukları görülmektedir.

Çizelge 6.1. Hisse senetlerinin 2008-2013 yılları arasındaki aylık kapanış değerlerinin dağılımına ilişkin istatistikler ve normal dağılım testi sonuçları (N=72).

Hisse Senedi	Ortalama Kapanış Fiyatı	Std. Sapma	Enk Kap. Fiyatı	Enb Kap. Fiyatı	Çarpıklık	Basıklık	W-İst.	Sig.
AKBANK	7,2574	1,3360	3,920	9,800	-0,432	-0,139	0,974	0,144
AKSA	3,6710	1,8908	1,280	8,540	0,8180	0,1060	0,909	0,000
ARÇELİK	7,3053	3,3180	1,610	14,20	0,2200	-0,565	0,966	0,046
ASYA KATILIM BANKASI	2,8468	1,9713	1,000	11,50	2,7930	8,1710	0,651	0,000
BİM MAĞ.	60,576	21,484	31,00	133,0	1,0740	0,9780	0,913	0,000
DOĞAN HLD.	1,0108	0,2836	0,510	1,730	0,4850	0,1180	0,964	0,038
ENKA İNŞ.	6,6669	3,2713	3,890	18,60	2,4720	5,2890	0,618	0,000
EREĞLİ DEMİR ÇELİK	4,2586	2,0657	1,930	11,30	1,4670	2,1770	0,854	0,000
GARANTİ BANKASI	6,4646	1,9581	2,070	9,900	-0,745	-0,054	0,927	0,000
İHLAS HLD.	0,8306	0,3950	0,200	2,180	0,9140	1,4200	0,946	0,004
İŞ BANKASI	5,1444	0,8806	3,280	6,960	-0,030	-0,428	0,986	0,582
KARDEMİR	0,9169	0,3296	0,460	2,020	0,9040	0,7310	0,934	0,001
KOÇ HLD.	6,1008	2,2851	2,120	10,85	0,1100	-0,831	0,971	0,090
PETKİM	4,1908	2,4754	1,820	11,80	1,2130	0,6380	0,822	0,000
SABANCI	6,7544	2,1021	2,460	12,00	0,2340	-0,279	0,986	0,628
SİNPAŞ	2,1975	1,3293	0,820	6,850	1,6310	2,1050	0,792	0,000
ŞİŞE CAM	2,3753	0,8277	0,950	4,270	0,0160	-1,015	0,959	0,020
T. HALK BNK.	11,315	4,0779	3,580	20,10	-0,016	-0,534	0,979	0,271
TEKFEN	5,7022	1,4423	2,620	9,400	-0,020	0,0600	0,985	0,577
TOFAŞ	6,8538	3,4154	1,130	14,05	0,3000	-0,579	0,967	0,056
TURKCELL	9,7151	1,2885	7,000	12,40	0,3090	-0,768	0,965	0,044
TÜPRAŞ	35,107	10,238	15,00	55,00	-0,362	-0,680	0,962	0,027
THY	5,1363	1,8060	2,120	8,850	0,0400	-0,939	0,966	0,046
TÜRK TRAKTÖR	27,084	19,864	3,680	68,00	0,6140	-0,825	0,893	0,000
VAKIFLAR BANKASI	3,4599	1,1606	1,080	6,400	-0,0860	0,0590	0,976	0,183
YAPI VE KREDİ BANK	3,6838	1,0497	1,650	5,680	-0,0610	-0,838	0,977	0,203

Çarpıklık ve basıklık ölçüleri bir serideki gözlem değerlerinin dağılımının şeklini ortaya koyan ölçülerdir. Bu ölçüler yorumlanırken normal dağılım özellikleri dikkate alınır. Normal dağılım eğrisi simetrik ve normal bir basıklığa sahiptir. Çarpıklık ölçüsü, serinin frekans dağılımının simetrik dağılımdan uzaklaşma derecesini gösterirken, basıklık ölçüsü verilerin normal dağılıma göre ortalama etrafında ne kadar yoğun bir şekilde dağıldığını gösteren ölçülerdir. Bir başka ifade ile çarpıklık ölçüsünün işaret büyüklüğü verinin çarpıklığının yön ve şiddetini gösterirken, basıklık ölçüsünün büyüklüğü verilerin ortalama civarında aşırı yoğunlaştığına, küçüklüğü ise verilerin ortalamaya etrafında fazla dağılmış olduğunu göstermektedir. Bir serinin simetriden ayrılmasına çarpıklık denir. Çarpıklık, bir dağılımın ortalaması etrafındaki asimetri derecesini belirtir. Serideki asimetri çarpıklık katsayılarına bakılarak anlaşılır. Çarpıklık katsayısı sıfır olan seri, simetrik seridir. Çarpıklık katsayısı negatif olduğunda seri, sola çarpık; pozitif olduğunda seri, sağa çarpık demektir (Ayvaz,2013).

Basıklık, bir dağılımın diklik derecesinin ölçüsüdür. Dağılımın normale göre daha basık olması, dağılımın değişkenliğinin fazla olduğunu gösterir. Dağılımın normale göre daha dik olması, serideki rakamların merkezi eğiliminin yüksek olduğunu gösterir (Ayvaz,2013).


Basıklık katsayısı değeri sıfırdan küçük ise dağılım normalden basık, yayvan ve veriler heterojendir. Sıfır ise dağılımın basıklığı normal dağılım kadardır. Sıfırdan büyük ise dağılım normalden sivridir ve veriler homojendir (Ayvaz,2013).

Örneğin Çizelge 6.1'de AKBANK hisse senedinin aylık kapanış fiyatının ortalaması 7.0669, standart sapması 1.43473, en küçük kapanış fiyatı 3.92 ve en büyük kapanış fiyatı 9.80'dir. Bu hisse senedi, -0.390 çarpıklık değeri ile sola çarpık ve -0.475 basıklık değeri ile normalden basık bir dağılıma sahiptir. Dağılım standart normal dağılıma uygun değildir. Uygun olması için her iki katsayının 0'a eşit olması gerekirdi.

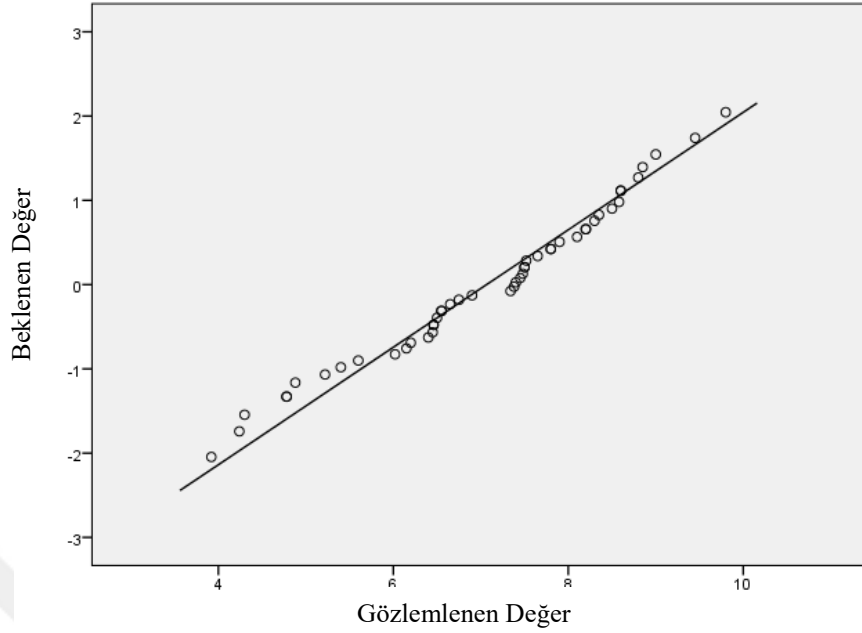
Wilk-Shapiro - W testine göre anlamlılık düzeyi (sig.) $p < 0.05$ düzeyinde anlamlı ise dağılımın normal olmadığı kararı verilir. Şayet $p > 0.05$ değeri elde edilmişse dağılımın normal dağılımdan anlamlı bir farklılık sergilemediği yorumu yapılır (Çolak, 2015).

Çizelge 6.1 incelendiğinde AKBANK, İŞBANKASI, KOÇ HOLDİNG, SABANCI, T. HALK BANKASI, TEKFEN, TOFAŞ, VAKIFLAR BANKASI, YAPI VE KREDİ BANK hisse senetlerinin anlamlılık düzeyleri $p > 0.05$ değeri olduğu için dağılımların normal dağılımdan anlamlı bir farklılık sergilemediği söylenebilir. Diğer hisse senetlerinin anlamlılık düzeyleri $p < 0.05$ düzeyinde anlamlı olduğu için dağılımlarının normal olmadığı kararı verilir.

Şekil 6.2’de AKBANK hisse senedine ait 2008-2011 yılları arasındaki aylık kapanış değerlerinin normal eğri ile birlikte verilen histogramı, Şekil 6.3’te ise bu hisse senedine ait kapanış fiyatlarının normal grafiği verilmektedir. Histograma bakıldığında değerlerin normal dağılım özellikleri göstermediği grafiğe bakıldığında ise gözlemlenen değerlerin beklenen normallikten sapmalar gösterdiği görülebilir.



Şekil 6.2. AKBANK hisse senedine ait kapanış fiyatlarının normal eğri ile birlikte verilen histogramı.



Şekil 6.3. AKBANK hisse senedine ait kapanış fiyatlarının normal grafiği.

6.2. Hisse Senedi Kapanış Fiyatlarının Tahminlenmesi

2008-2014 yılları arası hisse senedi kapanış fiyatları, hem Yapay Sinir Ağları ile hem de Zaman Serisi Analizi yöntemlerinden Üstel Düzeltme, Basit Ortalamalar, Hareketli Ortalamalar ve Trend Analizi ile tahmin edilmeye çalışılmıştır.

6.2.1. Yapay Sinir Ağları ile tahminleme

6.2.1.1. Veri ön işleme ve normalizasyon

Normalizasyon, üzerinde çalışılan ölçüm değerlerinin dağılımını daha düzenli bir hale getirmektedir. Veri setinde, veri setinin dağılımını etkileyecek aşırı (uç) değerler bulunabilmektedir. Bu uç değerler, YSA'nın çalışmasında yanlış yönde etkiler yapabilmektedir. Değerlerin belirli bir aralıkta tekrar düzenlenmesi, çok büyük ve küçük şeklindeki değerlerin etkisinin azalmasını sağlar. Verilerin 0-1 aralığına dönüştürülmesi veri normalizasyonu olarak isimlendirilmektedir. Bu işlem girdi nöronları ile çıktı nöronlarının ağıın kullanımına uygun bir şekilde analizinin yapılması ve uygulamada kullanılması için gereklidir. Böylece veriler bir ön işleminden geçirilerek YSA'da kullanılacak şekilde ölçeklendirilmiş olacaktır.

Uygulamada tek kutuplu lojistik aktivasyon fonksiyonu kullanılacağı için, veri normalleştirilmesi Denklem 6.1'de yer alan formülasyon kullanılarak her veri için ayrı ayrı yapılır.

$$P'_i = \frac{P_i - \text{Enk}(P_i)}{\text{Enb}(P_i) - \text{Enk}(P_i)} \quad (6.1)$$

burada;

P_i = i. hisse senedinin kapanış fiyatı

P'_i = normalleştirilen P_i giriş ya da çıkış nöronu,

$\text{Enk}(P_i)$ = giriş nöronlarına ait veri kümesindeki enküçük giriş nöron değeri,

$\text{Enb}(P_i)$ = giriş nöronlarına ait veri kümesindeki enbüyük değere sahip giriş nöronu değeridir.

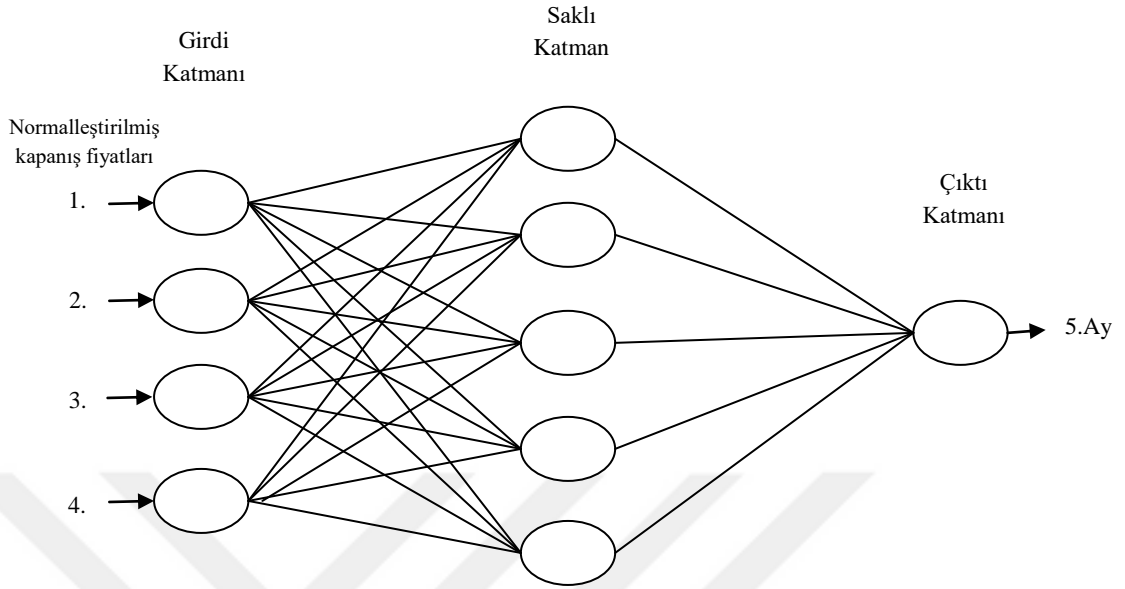
6.2.1.2. Tahminlerin gerçekleştirilmesi

Bu bölümde kullanılan YSA'nın parametrelerinin özeti Çizelge 6.2'de verilmektedir.

Çizelge 6.2. Kullanılan ağın parametreleri.

Ağın Türü:	MLP (Çok Katmanlı Algılayıcı)
Öğrenme Algoritması:	Geri Yayılım (Levenberg-Marquardt Geri Yayılım - Bayesyen Düzeltme Geri Yayılım)
Öğrenme Kuralı:	Delta Kuralı
Girdi Katmanındaki Nöron Sayısı:	4-6
Saklı Katmandaki Nöron Sayısı:	5-10-15-20
Çıktı Katmanındaki Nöron Sayısı:	1
Toplama Fonksiyonu:	Toplam Fonksiyonu
Aktivasyon Fonksiyonu:	Log Sigmoid Aktivasyon Fonksiyonu

Örnek olarak girdi katmanında 4 nörona, saklı katmanda 5 nörona sahip bir YSA örneği Şekil 6.4'te verilmektedir.



Şekil 6.4. Bağımlı değişkenin (5. ay) tahmininde kullanılan ağ yapısı.

YSA'nın dezavantajlarından biri de bir ağın nasıl oluşturulması gerektiğini belirleyen kuralların bulunmamasıdır. Uygun ağ deneme yanılma yoluyla bulunur. Ağ parametrelerinin seçimine ilişkin de herhangi bir kural yoktur. Her problem için ayrı ayrı değerlendirilmesi gerekir. Her bir katmanda kaç tane nöronun yer alacağına karar vermek karşılaşılan sorunlardan birisidir. Çıktı katmanı için bir sorun bulunmamaktadır; bu sayı istenilen çıktı sayısı ile belirlenebilmektedir. Esas sorun, girdi katmanında ve gizli katmanlarda nöron sayısını belirlemektir. Ne yazık ki, gizli katmanda en verimli şekilde kaç tane nöronun bulunacağı konusunda herhangi bir matematiksel test bulunmamaktadır. Deneme ve yanılma yöntemi uygulanarak karar verilmelidir (Detiene vd.,2003). Bu yüzden bu çalışmada girdi katmanındaki nöron sayısı 4 ve 6 ile denenirken, gizli katmandaki nöron sayıları 5, 10, 15 ve 20 olarak ayrı ayrı ayarlanarak uygun nöron sayıları bulunmaya çalışılmıştır. Ayrıca öğrenme algoritması seçimi de ağın yapısını etkilediği için iki algoritma ayrı ayrı denenmiştir. Bunun yanı sıra eğitim örneklerinin seçiminde de genel bir kural bulunmamaktadır. Bu yüzden eğitim örnekleri olarak 2008-2011, 2008-2012 ve 2008-2013 yıllarında gerçekleşen veriler kullanılarak uygulamalar ayrı ayrı gerçekleştirilmiştir.

Özet olarak, tahminler gerçekleştirilirken aşağıdaki amaçlar göz önünde bulundurulmuştur:

-Uygun zaman diliminin bulunması,

- Saklı katmandaki uygun nöron sayısının belirlenmesi,
- Uygun girdi değişkeni sayısının bulunması,
- Uygun öğrenme algoritmasının belirlenmesi.

Çizelge 6.3. Yapay Sinir Ağlarıyla tahminlemede karşılaştırılan ağ yapıları.

YSA No	Zaman Dilimi	Nöron Sayısı	Girdi Değişkeni Sayısı	Öğrenme Algoritması
1	2008-2012	5-10-15-20	4	Levenberg-Marquardt Geri Yayılım
2	2008-2013	5-10-15-20	4	Levenberg-Marquardt Geri Yayılım
3	2008-2014	5-10-15-20	4	Levenberg-Marquardt Geri Yayılım
4	2008-2014	5-10-15-20	6	Levenberg-Marquardt Geri Yayılım
5	2008-2014	5-10-15-20	4	Bayesyen Düzeltme Geri Yayılım

Çizelge 6.3' te görüldüğü gibi tahminlemenin ilk aşamasında veri seti zaman açısından 3 bölümde incelenip YSA 1, YSA 2 ve YSA 3 karşılaştırılmıştır. YSA 1'de 2008-2011 yılları arasındaki veriler eğitim seti olarak kullanılırken, 2012 yılındaki veriler test veri seti olarak, YSA 2'de 2008-2012 yılları arasındaki veriler eğitim seti olarak kullanılırken 2013 yılındaki veriler test veri seti olarak, son olarak da YSA 3'te 2008-2013 yılları arasındaki veriler eğitim seti olarak kullanılırken 2014 yılındaki veriler test veri seti olarak kullanılarak karşılaştırmalar yapılmıştır. Üç zaman dilimi için de kullanılan YSA modeli Çok Katmanlı İleri Beslemeli Yapay Sinir Ağı modelidir. Bu üç YSA karşılaştırılırken dört aylık kapanış değerleri girdi değişkeni olarak kullanılmış olup, beşinci ayın kapanış değeri çıktı değişkeni olarak kullanılmıştır. Her YSA çalıştırılırken saklı katmandaki nöron sayısı değiştirilerek sonuçlar karşılaştırılmıştır. Saklı katmanda karşılaştırılan nöron sayıları 5, 10, 15 ve 20'dir. Üç YSA için de kullanılan öğrenme algoritması Levenberg-Marquardt Geri Yayılım Algoritmasıdır. Buradaki amaç, aynı girdi değişken sayısı ve aynı öğrenme algoritmasına sahip uygun zaman diliminin ve uygun saklı katman nöron sayısının bulunmasıdır. Analizlerde MATLAB r2015a yazılımının Yapay Sinir Ağları aracı kullanılmıştır. Örnek olarak, AKBANK hisse senedi için, Çizelge 6.4, 6.5 ve 6.6 'da ilgili modeller ile gerçekleştirilen tahmin değerleri ile ilişkili aylara ait gerçek değerlerin normalize edilmiş biçimleri gösterilmektedir. EK 1, 2 ve 3'te uygulamaların performans sonuçları, tahmin edilen ve gerçek değerlerden faydalanılarak hesaplanan MSE, MAE, MAPE hata sonuçları gösterilmektedir. EK 1'de 2012 için, EK 2'de 2013 için, EK 3'te

2014 için modellerin ürettikleri tahmin değerleri, gerçekleşmiş olan aylık kapanış fiyatları ile karşılaştırılarak hangi modelin daha gerçekçi sonuçlar verdiği belirlenmiştir.

Çizelge 6.4. AKBANK hisse senedi için YSA 1 ile 2012 yılı için tahmin edilen değerler ve gerçek değerler.

Gerçek Değerler	Tahmin Edilen Değerler			
	5 Nöron	10 Nöron	15 Nöron	20 Nöron
0,475510	0,29715	0,41615	0,27772	0,32505
0,521769	0,39844	0,32191	0,34703	0,40373
0,519048	0,55909	0,42894	0,53059	0,49682
0,453741	0,63962	0,40010	0,55511	0,54506
0,342177	0,69176	0,33667	0,64982	0,56648
0,467347	0,29003	0,49993	0,26548	0,38213
0,486395	0,35586	0,32184	0,28481	0,32822
0,543537	0,51372	0,40474	0,47468	0,45147
0,532653	0,64776	0,47909	0,57938	0,59195
0,742177	0,63037	0,41867	0,57378	0,48097
0,706803	0,75546	0,47909	0,74007	0,73799
0,763946	0,67850	0,79702	0,68504	0,71619

Çizelge 6.5. AKBANK hisse senedi için YSA 2 ile 2013 yılı için tahmin edilen değerler ve gerçek değerler.

Gerçek Değerler	Tahmin Edilen Değerler			
	5 Nöron	10 Nöron	15 Nöron	20 Nöron
0,777551	0,74876	0,72165	0,76073	0,73729
0,755782	0,75731	0,73154	0,74178	0,74166
0,853741	0,76684	0,72873	0,75884	0,71795
0,848299	0,77871	0,74423	0,79238	0,72126
0,782993	0,79966	0,77016	0,77049	0,75958
0,636054	0,80422	0,75057	0,77987	0,66497
0,578912	0,74891	0,68620	0,62099	0,64635
0,489116	0,63268	0,55964	0,43607	0,61783
0,578912	0,54293	0,42156	0,50369	0,62412
0,633333	0,49183	0,49436	0,44345	0,53935
0,573469	0,58627	0,55292	0,66826	0,61778
0,478231	0,61954	0,64014	0,64354	0,64916

Çizelge 6.6. AKBANK hisse senedi için YSA 3 ile 2014 yılı için tahmin edilen değerler ve gerçek değerler.

Gerçek Değerler	Tahmin Edilen Değerler			
	5 Nöron	10 Nöron	15 Nöron	20 Nöron
0,350340	0,50870	0,66918	0,61414	0,49874
0,344898	0,38910	0,58611	0,65016	0,41868
0,491837	0,35729	0,50557	0,32309	0,40457
0,569388	0,50601	0,52655	0,64267	0,56313
0,679592	0,54434	0,71745	0,60600	0,59466
0,626531	0,63858	0,71096	0,31724	0,61067
0,727211	0,63189	0,55035	0,66455	0,67584
0,687755	0,70530	0,66194	0,73656	0,76260
0,576190	0,73075	0,65533	0,73890	0,71468
0,659184	0,57176	0,74300	0,63807	0,69340
0,789796	0,64324	0,64424	0,69774	0,68616
0,744898	0,75816	0,77954	0,78665	0,77329

Çizelge 6.7. Yıllara ve nöron sayılarına göre Yapay Sinir Ağı uygulaması performans sonuçları.

YSA No	Nöron Sayısı		5	10	15	20
1	2008- 2012 (4 Aylık) (LM)	MSE	0,012722	0,022935	0,023360	0,014508
		MAE	0,080743	0,105590	0,107270	0,082848
		MAPE	18,73462	23,66256	27,60348	19,07148
2	2008- 2013 (4 Aylık) (LM)	MSE	0,030087	0,021623	0,054670	0,049930
		MAE	0,106867	0,100493	0,154688	0,153479
		MAPE	18,59413	18,53758	24,66283	25,32561
3	2008- 2014 (4 Aylık) (LM)	MSE	<i>0,008068</i>	0,012337	0,009298	0,013919
		MAE	<i>0,062581</i>	0,075776	0,066583	0,073041
		MAPE	13,29136	14,70047	<i>13,16003</i>	15,10613

Çizelge 6.7'de yıllara ve nöron sayılarına göre 3 YSA yapısının Yapay Sinir Ağı uygulamalarının tüm hisse senetleri için hata ölçümlerinin ortalaması alınmış değerleri verilmiştir. Çizelgeden de anlaşılacağı üzere YSA 1, YSA 2 ve YSA 3 için MAE, MSE, MAPE değerleri karşılaştırıldığında her üç hata ölçümü için de en düşük hata değerlerini çizelgede koyu italik yazı tipi ile gösterilen 0,008068, 0,062581, 13,16003 değerleri ile YSA 3 vermektedir. Bu yüzden en uygun zaman dilimi YSA 3'teki 2008-2014 olarak seçilmiştir. Saklı katmandaki nöron sayısı bakımından ise MSE ve MAE hata ölçüm değerlerine göre 5 nöronun, MAPE ölçüm değerine göre ise 15 nöronun daha iyi sonuçlar verdiği anlaşılmaktadır.

Uygun zaman diliminin 2008-2014 olarak seçilmesinin ardından, tahminlerin girdi değişkeni sayısından etkilenip etkilenmediği araştırılmak istenmiştir. Bu yüzden girdi değişkeni sayısı 6 olarak değiştirilip yani ilk 6 ay girdi değişkeni olarak kullanılarak 7. Ayın tahmin edildiği YSA 4 oluşturulmuştur. Örnek olarak, AKBANK hisse senedi için, Çizelge 6.8'de YSA 4 ile gerçekleştirilen tahmin değerleri ile ilişkili aylara ait gerçek değerlerin normalize edilmiş biçimleri gösterilmektedir. YSA 4'ün performans sonuçları ve hata ölçümleri EK 4'te verilmektedir.

Çizelge 6.8. AKBANK hisse senedi için YSA 4 ile 2014 yılı için tahmin edilen değerler ve gerçek değerler.

Gerçek Değerler	Tahmin Edilen Değerler			
	5 Nöron	10 Nöron	15 Nöron	20 Nöron
0,350340	0,56828	0,54110	0,55325	0,55303
0,344898	0,45570	0,57207	0,47791	0,66487
0,491837	0,34157	0,52514	0,39410	0,67768
0,569388	0,44683	0,42596	0,44291	0,49123
0,679592	0,50364	0,57036	0,56928	0,52428
0,626531	0,64056	0,76853	0,73742	0,70006
0,727211	0,71855	0,72459	0,66420	0,52318
0,687755	0,76586	0,68012	0,67841	0,77284
0,576190	0,75293	0,66243	0,64085	0,82182
0,659184	0,64758	0,66746	0,60614	0,69037
0,789796	0,70528	0,66349	0,60783	0,64796
0,744898	0,71999	0,50775	0,65349	0,83727

Çizelge 6.9'da YSA 3 ve YSA 4'ün özet sonuçları verilmektedir. Bu sonuçlar incelendiğinde YSA 3'ün YSA 4'ten yani 4 girdi değişkeni kullanılan modelin 6 girdi değişkeni ile oluşturulan modelden daha iyi tahminler yaptığı anlaşılmıştır.

Çizelge 6.9. Yıllara ve nöron sayılarına göre Yapay Sinir Ağı uygulaması performans sonuçları.

YSA No	Nöron Sayısı		5	10	15	20
3	2008- 2014 (4 Aylık) (LM)	MSE	0,008068	0,012337	0,009298	0,013919
		MAE	0,062581	0,075776	0,066583	0,073041
		MAPE	13,29136	14,70047	13,16003	15,10613
4	2008- 2014 (6 Aylık) (LM)	MSE	0,012061	0,009570	0,011502	0,010071
		MAE	0,078377	0,072275	0,075278	0,072919
		MAPE	16,18935	14,25434	15,37730	14,80673

Uygun girdi değişkeni sayısının 4 olarak seçilmesinden sonra Yapay Sinir Ağı için seçilen öğrenme algoritmasının Yapay Sinir Ağının tahmin gücünü etkileyip etkilemediği araştırılmak istenmiştir. Bu yüzden diğer parametreler YSA 3 ile aynı tutulup öğrenme algoritması Bayesyen Düzeltme Geri Yayılım olarak değiştirilerek YSA 5 oluşturulmuştur. Örnek olarak, AKBANK hisse senedi için, Çizelge 6.10'da YSA 5 ile gerçekleştirilen tahmin değerleri ile ilişkili aylara ait gerçek değerlerin normalize edilmiş biçimleri gösterilmektedir. Bu model ile çalıştırılan Yapay Sinir Ağı uygulamasının performans sonuçları ve hata ölçüm değerleri EK 5'te verilmektedir.

Çizelge 6.10. AKBANK hisse senedi için YSA 5 ile 2014 yılı için tahmin edilen değerler ve gerçek değerler.

Gerçek Değerler	Tahmin Edilen Değerler			
	5 Nöron	10 Nöron	15 Nöron	20 Nöron
0,350340	0,53720	0,53257	0,53129	0,52333
0,344898	0,40824	0,41693	0,39117	0,38342
0,491837	0,36701	0,37328	0,35028	0,34571
0,569388	0,44881	0,45802	0,42955	0,43424
0,679592	0,57083	0,56556	0,55691	0,56875
0,626531	0,67401	0,65601	0,67944	0,68400
0,727211	0,65916	0,65531	0,65540	0,65664
0,687755	0,69319	0,68721	0,70157	0,69566
0,576190	0,67294	0,68920	0,66279	0,65970
0,659184	0,63163	0,62742	0,63195	0,62221
0,789796	0,61791	0,62941	0,61440	0,60209
0,744898	0,69498	0,71471	0,68723	0,68545

Çizelge 6.11 incelendiğinde, YSA 5'in MSE, MAE, MAPE olmak üzere üç hata ölçümüne göre koyu italik yazı tipi ile gösterilen 0,005197, 0,0532, 9,064911 değerleri ile YSA 3'ten daha iyi tahmin sonuçları verdiği anlaşılmaktadır. Yani Bayesyen Düzeltme Geri Yayılım öğrenme algoritması Levenberg-Marquardt Geri Yayılım algoritmasından daha iyi tahmin gücüne sahiptir. YSA 5'in sonuçları nöron sayısı bakımından incelendiğinde ise 3 hata ölçümünün ortalama değerlerine göre de 10 nöron sayısının daha az tahmin hatası yaptığı görülmektedir.

Çizelge 6.11. Yıllara ve nöron sayılarına göre yapay sinir ağı uygulaması performans sonuçları.

YSA No	Nöron Sayısı		5	10	15	20
3	2008- 2014 (4 Aylık) (LM)	MSE	0,008068	0,012337	0,009298	0,013919
		MAE	0,062581	0,075776	0,066583	0,073041
		MAPE	13,29136	14,70047	13,16003	15,10613
5	2008- 2014 (4 Aylık) (BR)	MSE	0,009208	0,005197	0,006726	0,009482
		MAE	0,063606	0,053200	0,060004	0,071741
		MAPE	10,42714	9,064911	10,11336	13,29131

Tüm modellerin verdiği sonuçları bir arada görüp daha sağlıklı yorumlanabilmesi açısından Çizelge 6.12 oluşturulmuştur. Bu çizelgeden de görülebileceği gibi, YSA 5 ile en iyi tahmin sonuçları elde edilmiştir.

Çizelge 6.12. Yıllara ve nöron sayılarına göre Yapay Sinir Ağı uygulaması performans sonuçları.

YSA No	Nöron Sayısı		5	10	15	20
1	2008- 2012 (4 Aylık) (LM)	MSE	0,012722	0,022935	0,023360	0,014508
		MAE	0,080743	0,105590	0,107270	0,082848
		MAPE	18,73462	23,66256	27,60348	19,07148
2	2008- 2013 (4 Aylık) (LM)	MSE	0,030087	0,021623	0,054670	0,049930
		MAE	0,106867	0,100493	0,154688	0,153479
		MAPE	18,59413	18,53758	24,66283	25,32561
3	2008- 2014 (4 Aylık) (LM)	MSE	0,008068	0,012337	0,009298	0,013919
		MAE	0,062581	0,075776	0,066583	0,073041
		MAPE	13,29136	14,70047	13,16003	15,10613
4	2008- 2014 (6 Aylık) (LM)	MSE	0,012061	0,009570	0,011502	0,010071
		MAE	0,078377	0,072275	0,075278	0,072919
		MAPE	16,18935	14,25434	15,37730	14,80673
5	2008- 2014 (4 Aylık) (BR)	MSE	0,009208	0,005197	0,006726	0,009482
		MAE	0,063606	0,053200	0,060004	0,071741
		MAPE	10,42714	9,064911	10,11336	13,29131

RMSE ve MAE değerlerinin düşük olması, MAPE (%) değerleri içinde Witt ve Witt (1992)'in bildirdiği %10'un altında olan tahmin modellerinin yüksek doğruluk derecesine, %10 ile %20 arasında olan modellerin ise doğru tahminler olarak sınıflandırılması esas alınmıştır. Ayrıca, benzer şekilde Lewis (1982)'in bildirdiği, MAPE değerleri %10'un altında olan modelleri çok iyi, %10 ile %20 arasında olanları iyi olarak sınıflandırılması (Çuhadar ve

Kayacan, 2005) gerektiği bildirimine de yer verilmiştir. Bu ölçütlere göre YSA 3 tüm nöron sayıları için iyi tahmin grubuna girerken, YSA 5, 10 nöron sayısı için çok iyi, diğer nöron sayıları için iyi tahmin grubuna girmektedir.

YSA 5'in en iyi sonuçları sağlamasına rağmen, YSA 3 ve YSA 5 birbirine yakın sonuçlar vermektedir. Portföy Optimizasyonu analizinde bu iki modelden faydalanılacağı için sözü edilen modellere ilişkin tahmin edilen değerler, tahmin çalışmasından sonra normalizasyon işleminin tersi uygulanarak kendi ölçeklerine çevrilmiştir. Örnek olarak, AKBANK hisse senedi için, Çizelge 6.13 ve 6.14'te ilgili modeller ile gerçekleştirilen tahmin değerleri ile ilişkili aylara ait gerçek değerlerin kendi ölçeklerindeki biçimleri gösterilmektedir.

Çizelge 6.13. AKBANK hisse senedi için YSA 3 ile saklı katmandaki 5-10-15-20 nöron sayıları için tahmin edilen değerler ve gerçek değerler (normalize edilmiş değerler tahmin çalışmasından sonra kendi ölçeklerine çevrilmiştir).

Gerçek Değerler	Tahmin Edilen Değerler			
	5 Nöron	10 Nöron	15 Nöron	20 Nöron
5,76	6,920000	8,103473	7,698929	6,850739
5,72	6,044885	7,492909	7,963676	6,262298
6,80	5,811082	6,900940	5,559712	6,158590
7,37	6,904174	7,055143	7,908625	7,324006
8,18	7,185899	8,458258	7,639100	7,555751
7,79	7,878563	8,410556	5,516714	7,673425
8,53	7,829392	7,230073	8,069443	8,152424
8,24	8,368955	8,050259	8,598716	8,790110
7,42	8,556013	8,001676	8,615915	8,437898
8,03	7,387436	8,646050	7,874815	8,281490
8,99	7,912814	7,920164	8,313389	8,228276
8,66	8,757476	8,914619	8,966878	8,868682

Çizelge 6.14. AKBANK hisse senedi için YSA 5 ile saklı katmandaki 5-10-15-20 nöron sayıları için tahmin edilen değerler ve gerçek değerler (normalize edilmiş değerler tahmin çalışmasından sonra kendi ölçeklerine çevrilmiştir).

Gerçek Değerler	Tahmin Edilen Değerler			
	5 Nöron	10 Nöron	15 Nöron	20 Nöron
5,76	7,130000	7,099390	7,089982	7,031476
5,72	6,185564	6,249436	6,060100	6,003137
6,80	5,882524	5,928608	5,759558	5,725969
7,37	6,483754	6,551447	6,342193	6,376664
8,18	7,380601	7,341866	7,278289	7,365313
7,79	8,138974	8,006674	8,178884	8,212400
8,53	8,029826	8,001529	8,002190	8,011304
8,24	8,279947	8,235994	8,341540	8,298101
7,42	8,131109	8,250620	8,056507	8,033795
8,03	7,827481	7,796537	7,829833	7,758244
8,99	7,726639	7,811164	7,700840	7,610362
8,66	8,293103	8,438119	8,236141	8,223058

6.2.2. Zaman Serileri Yöntemleriyle Tahminleme

Bu yöntem, geçmişin gözlemine dayanılarak geleceğe ait tahminlerde bulunmak esasına dayanır. Geçmişin gözlemi ise belirli aralıklarla toplanan istatistiksel veriler, başka bir deyimle zaman serileri ile yapılabilir. Zaman serilerinden yararlanılarak, üretimi öngörülen mal ve hizmetin geçmiş yıllardaki tüketiminin göstermiş olduğu eğilim saptanır ve gelecekteki talebin de aynı şekilde gelişeceği kabul edilerek tahminler yapılır.

Bu çalışmada, Yapay Sinir Ağları yöntemiyle karşılaştırılmak üzere zaman serisi yöntemlerinden Basit Ortalama Yöntemi, Hareketli Ortalamalar Yöntemi, Üstel Düzeltme Yöntemi ve Trend Analizi Yöntemi seçilmiştir. Bu bölümde tahminler, Microsoft Office Excel programında ilgili yöntemlere ait formüller kullanılarak gerçekleştirilmiştir.

Çalışmada, 2008-2014 yılları arasındaki 84 aylık kapanış verileri kullanılmış olup, 2014 yılındaki 12 aylık kapanış verileri tahmin edilmiştir. MAPE hata ölçümü değerleri 2014 yılındaki 12 aylık tahmini ve gerçek veriler üzerinden hesaplanmıştır. Yöntem, 26 hisse senedi için de ayrı ayrı uygulanmıştır.

6.2.2.1. Basit Ortalama Yöntemi ile tahminleme

Örnek olarak, AKBANK hisse senedi için Basit Ortalama Yöntemi ile tahmin edilen değerler ve gerçek değerler Çizelge 6.15'te verilmektedir. Yöntemden elde edilen MAPE değerleri Çizelge 6.19'da verilmiştir.

Çizelge 6.15. Basit Ortalama Yöntemi ile tahmin edilen değerler ve gerçek değerler.

2014 Ayları	Tahmin Edilen Değerler	Gerçek Değerler
1	7,257361	5,76
2	7,236849	5,72
3	7,216351	6,80
4	7,210800	7,37
5	7,212895	8,18
6	7,225455	7,79
7	7,232692	8,53
8	7,249114	8,24
9	7,261500	7,42
10	7,263457	8,03
11	7,272805	8,99
12	7,293494	8,66

6.2.2.2. Hareketli Ortalamalar Yöntemi ile tahminleme

Bölüm 3'te bahsedildiği gibi, Hareketli Ortalamalar Yöntemi'nin cebirsel formülü şu şekildedir:

$$\hat{Y}_i = \frac{Y_{i-1} + Y_{i-2} + \dots + Y_{i-n}}{n} \quad (6.2)$$

Hareketli Ortalamalar Yöntemi'nde n değerinin nasıl seçileceği konusunda uyulacak genel bir kural yoktur. Genellikle 2 ile 7 arasında değişen farklı n değerleri alınarak, en düşük ortalama tahmin hatasını (tahmin değerleri ile gerçekleşen değerler arasındaki fark) veren n değeri tercih edilir (Yavuz, 2013).

Çalışmada, n değeri 4 olarak seçilmiştir. Bunun nedeni ise, karşılaştırılacak olan Yapay Sinir Ağları Yönteminde girdi değişken sayısının 4 olarak belirlenmiş olmasıdır. Böylece yöntemler arasındaki karşılaştırmalar daha sağlıklı olacaktır. Örnek olarak, AKBANK hisse senedi için Hareketli Ortalama Yöntemi ile tahmin edilen değerler ve gerçek değerler Çizelge 6.16'da verilmektedir. Yöntemden elde edilen MAPE değerleri Çizelge 6.19'da verilmiştir.

Çizelge 6.16. Hareketli Ortalamalar Yöntemi ile tahmin edilen değerler ve gerçek değerler.

2014 Ayları	Tahmin Edilen Değerler	Gerçek Değerler
1	7,35	5,76
2	6,93	5,72
3	6,40	6,80
4	6,25	7,37
5	6,41	8,18
6	7,02	7,79
7	7,54	8,53
8	7,97	8,24
9	8,19	7,42
10	8,00	8,03
11	8,06	8,99
12	8,17	8,66

6.2.2.3. Üstel Düzeltme Yöntemi ile tahminleme

Düzeltme faktörü olan (α), geçmiş göz önünde bulundurularak, araştırmacının arzusuna göre 0 ile 1 sınırları içinde keyfi olarak seçilir. Ayrıca 1. dönem tahmin değeri F_1 , genellikle 1. dönem gerçekleşen değer aynısı olarak alınır. En uygun α değerini bulmak amacıyla yöntem, $\alpha = 0.1, 0.2, 0.3, 0.4, 0.5, 0.6, 0.7, 0.8, 0.9$ için ayrı ayrı uygulanarak MAPE değerleri hesaplanmıştır. Hesaplama sonuçları EK 6'da verilmektedir. Ekten de görüldüğü gibi 7,4315 değeri ile en küçük ortalama MAPE değerini veren α katsayısı 0.9'dur. Bu yüzden Çizelge 6.19'daki MAPE değerlerinin karşılaştırılmasında $\alpha = 0.9$ katsayısından elde edilen sonuçlar kullanılmıştır. Örnek olarak, AKBANK hisse senedi için Üstel Düzeltme Yönteminin α katsayısı 0.9 ile tahmin edilen değerler ve gerçek değerler Çizelge 6.17'de verilmektedir.

Çizelge 6.17. Üstel Düzeltme Yönteminin α katsayısı 0.9 ile 2014 yılı için tahmin edilen değerler ve gerçek değerler.

2014 Ayları	Tahmin Edilen Değerler	Gerçek Değerler
1	6,77	5,76
2	5,86	5,72
3	5,73	6,80
4	6,69	7,37
5	7,30	8,18
6	8,09	7,79
7	7,82	8,53
8	8,46	8,24
9	8,26	7,42
10	7,50	8,03
11	7,98	8,99
12	8,89	8,66

6.2.2.4. Trend Analizi Yöntemi ile tahminleme

Örnek olarak, AKBANK hisse senedi için Trend Analizi Yöntemi ile tahmin edilen değerler ve gerçek değerler Çizelge 6.18'de verilmektedir. Yöntemden elde edilen MAPE değerleri Çizelge 6.19'da verilmiştir.

Çizelge 6.18. Trend Analizi Yöntemi ile tahmin edilen değerler ve gerçek değerler.

2014 Ayları	Tahmin Edilen Değerler	Gerçek Değerler
1	8,21	5,76
2	8,24	5,72
3	8,27	6,80
4	8,29	7,37
5	8,32	8,18
6	8,34	7,79
7	8,37	8,53
8	8,40	8,24
9	8,42	7,42
10	8,45	8,03
11	8,48	8,99
12	8,50	8,66

Çizelge 6.19. Karşılaştırılan yöntemlerden elde edilen MAPE sonuçları.

Hisse Senedi	Levenberg-Marquardt Geri Yayılım Algoritması				Bayesyen Düzeltme Geri Yayılım Algoritması				Basit Ortalama Yöntemi	Hareketli Ortalamalar Yöntemi	Üstel Düzeltme Yöntemi	Trend Analizi Yöntemi
	YSA (5 Nöron)	YSA (10 Nöron)	YSA (15 Nöron)	YSA (20 Nöron)	YSA (5 Nöron)	YSA (10 Nöron)	YSA (15 Nöron)	YSA (20 Nöron)				
AKBANK	8,847513	11,39152	14,42517	7,203090	9,036460	8,789879	9,335251	9,209413	12,80532	11,93	8,530	13,300
AKSA	5,843253	14,37778	15,19102	5,150442	6,227419	4,624856	6,997109	7,740498	46,59374	5,480	5,620	5,3500
ARÇELİK	5,800560	11,08345	6,234957	6,691346	6,053794	6,385278	6,992640	7,754904	40,67615	6,870	5,550	4,5700
ASYA												
KATILIM BANKASI	35,84825	29,38616	23,46221	28,50418	27,85462	31,66902	26,58931	29,85046	161,2303	34,21	15,86	18,330
BİM												
MAĞAZALAR	4,953380	6,399545	5,421634	5,545035	5,369306	5,396050	5,204260	5,458232	26,19690	5,580	5,540	29,240
DOĞAN HOLDİNG	7,099690	7,090432	5,694588	9,073680	4,565550	6,059983	5,796006	32,17682	35,11633	10,83	5,970	8,6700
ENKA												
İNŞAAT	4,220913	7,168124	5,732877	5,138963	6,486092	4,818724	5,282343	5,445195	14,21367	5,960	4,660	52,740
EREĞLİ												
DEMİR	8,573997	9,743512	7,075859	11,00782	9,408414	8,809627	9,762295	9,157825	25,53215	11,26	7,890	69,330
ÇELİK												
GARANTİ BANKASI	10,75948	9,615128	11,81734	9,587316	8,332665	8,140453	8,538614	8,594372	20,06873	11,93	7,690	16,310
İHLAS												
HOLDİNG	24,71287	23,29692	13,58583	20,06467	9,575315	11,85588	16,79485	38,06221	143,9482	20,04	10,50	264,44
İŞ BANKASI	10,98455	10,27226	11,19281	12,01139	9,843359	9,139148	11,84737	9,936179	13,29167	13,08	8,870	12,770
KARDEMİR	23,92183	36,18194	18,48095	14,08480	22,70107	12,46598	12,81195	17,22880	43,20771	16,34	11,91	30,030
KOÇ												
HOLDİNG	11,50953	7,561719	9,380462	8,415983	8,995175	10,00598	12,77725	25,63919	37,66135	10,22	6,470	9,6600
PETKİM	6,221903	8,954644	6,665179	9,329464	5,661056	5,100542	5,398420	6,353975	31,55322	10,47	5,590	59,810
SABANCI	6,135363	12,13379	9,737319	6,453793	5,066017	4,902665	5,029981	5,112552	25,96417	8,320	5,600	11,660
SİNPAŞ	25,57430	7,346823	8,894847	38,69438	24,37789	16,78262	21,77293	35,48965	161,1217	13,17	6,850	72,690
ŞİŞE CAM	8,483610	8,740232	13,23544	7,584632	8,529411	7,562534	7,326366	6,201518	17,61584	11,26	7,030	25,440

Çizelge 6.19. Karşılaştırılan yöntemlerden elde edilen MAPE sonuçları (devamı).

Hisse Senedi	Levenberg-Marquardt Geri Yayılım Algoritması				Bayesyen Düzeltme Geri Yayılım Algoritması				Basit Ortalama Yöntemi	Hareketli Ortalamalar Yöntemi	Üstel Düzeltme Yöntemi	Trend Analizi Yöntemi
	YSA (5 Nöron)	YSA (10 Nöron)	YSA (15 Nöron)	YSA (20 Nöron)	YSA (5 Nöron)	YSA (10 Nöron)	YSA (15 Nöron)	YSA (20 Nöron)				
T. HALK BANKASI	10,60490	16,15284	14,78593	8,388958	11,66876	8,567560	7,907318	7,389673	19,45118	13,49	8,52	30,03
TEKFEN	5,999778	5,802451	7,227501	5,580188	5,629287	6,451937	6,715679	6,855670	9,816341	5,590	6,09	17,83
TOFAŞ	9,307597	8,829374	7,190228	13,60231	8,673806	10,44951	9,967510	13,26589	44,39117	9,420	6,50	6,480
TURKCELL	5,007565	8,885351	5,811845	24,85862	6,494149	5,451469	5,250111	4,019030	22,05149	6,840	5,21	12,97
TÜPRAŞ	9,915054	7,939929	7,308571	9,220219	8,303742	9,185185	8,728470	7,795906	24,01987	9,390	7,18	10,25
TÜRK HAVA YOLLARI	8,091139	9,879191	7,832599	9,197826	10,62866	7,610360	7,626942	7,940846	25,75968	8,630	6,14	28,12
TÜRK TRAKTÖR	11,18621	11,52909	10,68011	15,24799	24,81341	8,523828	13,13554	11,07205	54,95958	9,390	6,25	7,820
VAKIFLAR BANKASI	11,03601	13,88624	14,15336	12,50742	8,535487	8,255198	14,50082	15,09255	21,54774	13,16	8,58	16,04
YAPI VE KREDİ BANK	8,642323	10,00991	11,47642	10,22474	8,274629	8,683413	10,85799	12,73054	19,58241	12,50	8,62	16,93
ORTALAMA	11,12621	12,06378	10,48827	12,05266	10,42714	9,064911	10,11336	13,29131	42,24525	11,36	7,4315	32,72346

Çizelge 6.19’da görüldüğü gibi, karşılaştırılan yöntemlerden en düşük MAPE değerini **7.4315** ile Üstel Düzeltme Yöntemi vermektedir. Bunu izleyen ikinci yöntem **9,064911** MAPE değerine sahip Bayesyen Düzeltme Geri Yayılım öğrenme algoritması ile YSA (10 Nöronlu), üçüncü yöntem ise **10,48827** MAPE değerini veren Levenberg-Marquardt Geri Yayılım öğrenme algoritması ile YSA (15 Nöronlu) dur. Çizelge 6.19’daki Levenberg-Marquardt Geri Yayılım öğrenme algoritması ve Bayesyen Düzeltme Geri Yayılım öğrenme algoritması ile Yapay Sinir Ağı yöntemlerinin MAPE değerleri hesaplanmadan önce bu yöntemlerle elde edilen tahmin değerleri normalize edilmiş değerler olduklarından, diğer yöntemlerle kıyaslanmanın daha sağlıklı olması açısından bu tahmini değerler normalizasyon denkleminin ters uygulanmasıyla gerçek değerlerine çevrilmiştir.

6.3. Tahmin Hatalarının Karşılaştırılması (Varyans Analizi- Tek Yönlü ANOVA)

Varyans analizi, iki yada daha fazla ortalama arasında fark olup olmadığı ile ilgili hipotezi test etmek için kullanılır. Varyans analizinde bağımlı ve bağımsız değişkenlerden bahsedilir. Bağımsız değişkenlerin bağımlı değişken üzerindeki etkisi araştırılır. Bu çalışmadaki bağımlı değişken MAPE değerleri iken, bağımsız değişken karşılaştırılan yöntemlerdir (Doymuş, 2008).

Bağımlı ve bağımsız değişkenin durumuna göre varyans analizinin türü değişmektedir. Çizelge 6.20’de bağımlı ve bağımsız değişken sayılarına göre varyans analizlerinin türü özetlenmiştir (Doymuş, 2008).

Çizelge 6.20. Varyans analizi çeşitleri.

		Bağımsız Değişken Sayısı	
		Bir	İki
Bağımlı Değişken Sayısı	Bir	Tek Yönlü ANOVA	İki Yönlü ANOVA
	Birden Fazla	Tek Yönlü MANOVA	İki Yönlü MANOVA

Tek Yönlü ANOVA'da iki temel varsayım vardır. Her bir grup normal dağılımdan gelir ve görel olarak grupların varyansları homojendir. Varyansların homojenliği testi Levene Testi ile yapılır. Analizler 0,05 anlamlılık düzeyinde gerçekleştirilmiştir.

Çizelge 6.21. MAPE değişkenine göre tanımlayıcı istatistikler.

No.	Yöntem	Sayı	Ortalama	Std. Sapma	Std. Hata	Ortalama İçin %95 Güven Aralığı		Enk	Enb
						Alt Sınır	Üst Sınır		
1	YSA (5 Nöron) (LM)	26	11,12621	7,69060	1,50825	8,01991	14,2325	4,2209	35,8483
2	YSA (10 Nöron) (LM)	26	12,06378	7,15375	1,40297	9,17432	14,9532	5,8024	36,1820
3	YSA (15 Nöron) (LM)	26	10,48827	4,48388	0,87936	8,67719	12,2994	5,4216	23,4622
4	YSA (20 Nöron) (LM)	26	12,05266	7,94593	1,55832	8,84323	15,2621	5,1390	38,6944
5	YSA (5 Nöron) (BR)	26	10,42714	6,60179	1,29472	7,76062	13,0937	4,5656	27,8546
6	YSA (10 Nöron) (BR)	26	9,064911	5,36559	1,05228	6,89770	11,2321	4,6249	31,6690
7	YSA (15 Nöron) (BR)	26	10,11336	5,25786	1,03115	7,98966	12,2371	5,0299	26,5893
8	YSA (20 Nöron) (BR)	26	13,29131	10,1024	1,98125	9,21085	17,3718	4,0190	38,0622
9	Basit Ortalama	26	42,24525	43,3236	8,49645	24,7465	59,7440	9,8163	161,230
10	Hareketli Ortalamalar	26	11,36000	5,79608	1,13671	9,01891	13,7011	5,4800	34,2100
11	Üstel Düzeltme	26	7,431538	2,42567	0,47571	6,45179	8,41129	4,6600	15,8600
12	Trend Analizi	26	32,72346	51,0556	10,0128	12,1016	53,3452	4,5700	264,440
Toplam		312	15,19899	22,38098	1,26707	12,7059	17,6921	4,0190	264,440

Çizelge 6.22. Varyansların homojenliği testi.

Levene İstatistiği	df1	df2	Sig.
8,337	11	300	0,000

Çizelge 6.23. ANOVA sonuçları.

	Karelerin Toplamı	df	Ortalama Kare	F	Sig.
Gruplar Arasında	32814,245	11	2983,113	7,278	0,000
Gruplar İçerisinde	122968,274	300	409,894		
Toplam	155782,520	311			

Öncelikle ANOVA çizelgesindeki sig.(anlamlılık(p)) değeri incelenir. $p > 0,05$ ise gruplar arasında anlamlı bir fark yoktur. $p < 0,05$ ise gruplar arasında incelenen özellik bakımından anlamlı fark olduğu anlaşılır. Çizelge 6.23'te verilmekte olan ANOVA sonuçları incelendiğinde, "Sig." değeri $p = 0,000$ ($p < 0,05$) olduğu için tek yönlü varyans analizi için olan H_0 hipotezi reddedilir. Yani "%95 güvenle, grupların ortalamaları arasında istatistiksel olarak anlamlı bir farklılık vardır." denilebilir.

Gruplar arasında fark var ise; Çizelge 6.22'de görülen varyansların homojenliği testi çizelgesindeki sig.(anlamlılık(p)) değeri incelenir. $p > 0,05$ ise varyanslar homojen dağılmıştır, $p < 0,05$ ise varyanslar homojen dağılmamıştır. Varyansların homojenliği testinde, $p = 0,000$ ($p < 0,05$) olduğundan varyansların homojen dağılmamış olduğu anlaşılmaktadır. Bu yorum uygulanacak post-hoc testi belirlemek için kullanılır.

Post-hoc Testi, eğer varyans analizi sonucunda gruplar arasında bir fark bulunmuşsa, farklılığın hangi gruplardan kaynaklandığını tespit etmek için kullanılır. Post-hoc testlerinde birçok seçenek bulunmaktadır. Hepsinin temel işlevi aynıdır (<http://volkaniset.blogspot.com.tr>).

Burada varyansların homojen olması halinde yapılacak testlerden, genellikle "Tukey" testi tercih edilir. Veri sayısının az olduğu zamanlarda "Bonferroni" testi de seçilebilir. Varyansların homojen olmaması halinde yapılacak testlerden ise genellikle "Tamhane's T2" testi tercih edilir (<http://volkaniset.blogspot.com.tr>).

Buraya kadar, gruplar arasında MAPE değerleri bakımından fark olduğu ve varyansların homojen dağılmadığı tespit edilmiştir.

Bundan sonra farklılığın hangi gruplar arasında olduğu post-hoc testi yapılarak anlaşılır. Grupların varyansları homojen olmadığı için "Tamhane" testi uygulanmıştır.

Çizelge 6.24. Tamhane Testi çoklu karşılaştırmalar.

Bağımlı Değişken:	Ortalama Fark	Standart Sapma	Sig.	%95 Güven Aralığı		
				Alt Sınır	Üst Sınır	
MAPE						
6	9	-33,180344*	8,561368	0,042	-65,790174	-0,570513
9	11	34,813716*	8,509761	0,025	2,2971797	67,330252

Tamhane testinde her grubun ikişerli karşılaştırmaları yapılmış ve bu karşılaştırılan grupların ortalamaları arasındaki farklar (Ortalama Farkı) sayısal olarak bulunmuştur. Bu sayısal değerlerin yanında bir yıldız (*) işaretinin bulunması bu ikilinin ortalamaları arasında anlamlı bir farklılık olduğunu göstermektedir. Karşılaştırma sonuçları çok uzun olduğu için Çizelge 6.24'te sadece yıldız işaretli karşılaştırmaların sayısal sonuçları verilmiştir. Çizelge incelendiğinde 6-9 (YSA (10 Nöron) (BR) – Basit Ortalama) ve 9-11 (Basit Ortalama – Üstel Düzeltme) ikililerinin yanında bir yıldız (*) işareti olduğu görülür. Yani bu ikililerin ortalamaları arasında anlamlı bir farklılık vardır.

Son olarak Çizelge 6.21'deki "Tanımlayıcı İstatistikler" incelendiğinde Üstel Düzeltme Yöntemi grubunun ortalamasının diğer gruplardan daha küçük olduğu görülür. Yani Üstel Düzeltme Yönteminin MAPE değerinin, diğer yöntemlerin MAPE değerlerinden daha az olduğu söylenebilir. Bunu izleyen ikinci en az yöntem ise Bayesyen Düzeltme Geri Yayılım öğrenme algoritması ile 10 Saklı Nörona sahip Yapay Sinir Ağları Yöntemidir.

6.4. Tahminlerin Birleşimi için Farklı Modeller Temelli Portföy Optimizasyonu

6.4.1. Mevcut veriler ile tahmin verilerinin Markowitz'in Ortalama-Varyans Modeli yardımıyla karşılaştırılması


Çeşitli yöntemlerle tahminler yapıldıktan sonra en verimli modelin bulunabilmesi amacıyla farklı veriler ile portföy optimizasyonu gerçekleştirilmiştir. Kullanılan verilere göre önerilen modeller aşağıdaki gibi sıralanabilir.

Model 0 = 2014 yılına ait gerçek verilerin kullanılması. Bu model farklı tahmin verileri kullanılarak oluşturulan portföy optimizasyon modellerinin performanslarını, gerçek veriler ile oluşturulan portföy optimizasyon modeli ile karşılaştırmak amacıyla kullanılmıştır.

Model 1 = 2008-2013 yılları arasındaki veriler kullanılarak üstel düzeltme yöntemiyle 2014 yılı kapanış fiyatlarının tahmin edilmesiyle elde edilen tahmin sonuçlarının portföy optimizasyon modelinde kullanılması.

Model 2 = 2008-2013 yılları arasındaki veriler kullanılarak 5 – 10 – 15 - 20 nöron sayıları için YSA 3 ve YSA 5'den her bir hisse senedi için hangi YSA ve nöron sayısı gerçeğe daha yakın tahmin sonucu veriyorsa, 2014 yılı kapanış fiyatlarında ilgili tahmin sonuçlarının portföy optimizasyon modelinde kullanılması.

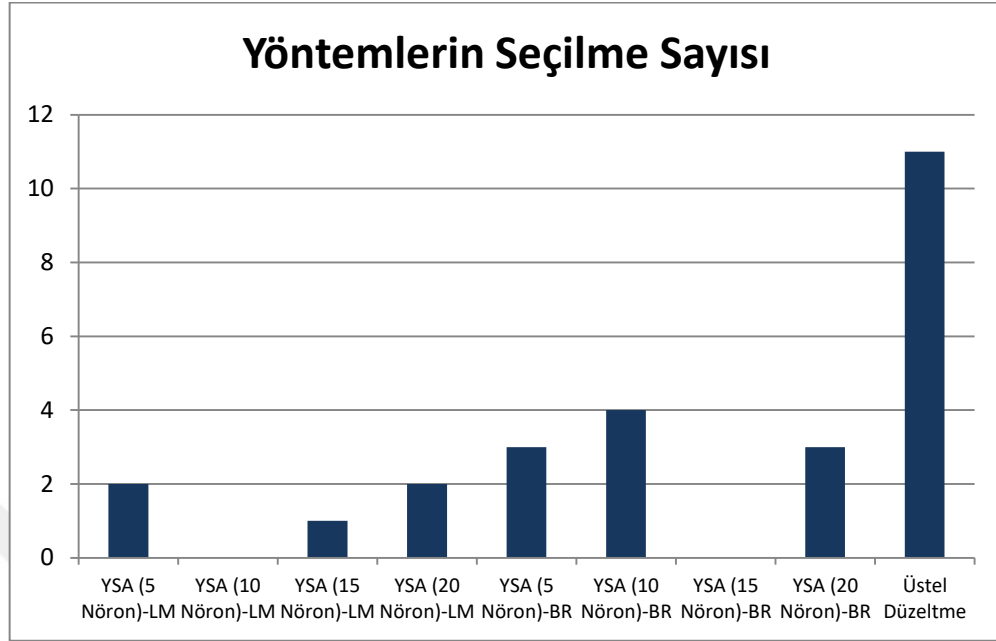
Seimler, hisse senedi bazında karřılařtırılmalar yapılarak gerekleřtirilmiřtir. Seimlerin nasıl yapıldıęı EK 7’de gsterilmektedir. rneęin, AKBANK hisse senedi iin 7,20309 MAPE deęerini veren Levenberg-Marquardt Geri Yayılım Algoritmasına sahip YSA (20 nron) Yntemi seilirken, AKSA hisse senedi iin 4,624856 MAPE deęeri ile Bayesyen Dzeltme Geri Yayılım Algoritmasına sahip YSA (10 nron) Yntemi seilmiřtir. řekil 6.5’te yntemlerin seilme sayıları gsterilmektedir.



řekil 6.5. Model 2’ye gre yntemlerin seilme sayıları.

Model 3 \equiv 2008-2013 yılları arasındaki veriler kullanılarak YSA 3, YSA 5 ve stel Dzeltme Yntemlerinden 2014 yılı kapanıř fiyatlarını eniyi tahmin edenin sonularının portfy optimizasyon modelinde kullanılması.

Seimlerin nasıl yapıldıęı EK 8’de gsterilmektedir. rneęin, AKSA hisse senedi iin 4,624856 MAPE deęeri ile Bayesyen Dzeltme Geri Yayılım Algoritmasına sahip YSA (10 nron) Yntemi seilirken, ARELİK hisse senedi iin 5,55 MAPE deęeri ile stel Dzeltme Yntemi seilmiřtir. řekil 6.6’da yntemlerin seilme sayıları gsterilmektedir.



Şekil 6.6. Model 3'e göre yöntemlerin seçilme sayıları.

Çizelge 6.25. Model 2 ve Model 3 ile elde edilen MAPE değerleri.

Hisse Senedi	Model 2'nin MAPE Değerleri	Model 3'ün MAPE Değerleri
AKBANK	7,203090	7,203090
AKSA	4,624856	4,624856
ARÇELİK	5,800560	5,550000
ASYA KATILIM BANKASI	23,46221	15,86000
BİM MAĞAZALAR	4,953380	4,953380
DOĞAN HOLDİNG	4,565550	4,565550
ENKA İNŞAAT	4,220913	4,220913
EREĞLİ DEMİR ÇELİK	7,075859	7,075859
GARANTİ BANKASI	8,140453	7,690000
İHLAS HOLDİNG	9,575315	9,575315
İŞ BANKASI	9,139148	8,870000
KARDEMİR	12,46598	11,91000
KOÇ HOLDİNG	7,561719	6,470000
PETKİM	5,100542	5,100542
SABANCI	4,902665	4,902665
SİNPAŞ	7,346823	6,850000
ŞİŞE CAM	6,201518	6,201518
T. HALK BANKASI	7,389673	7,389673
TEKFEN	5,580188	5,580188
TOFAŞ	7,190228	6,500000
TURKCELL	4,019030	4,019030
TÜPRAŞ	7,308571	7,180000
TÜRK HAVA YOLLARI	7,610360	6,140000
TÜRK TRAKTÖR	8,523828	6,250000
VAKIFLAR BANKASI	8,255198	8,255198
YAPI VE KREDİ BANK	8,274629	8,274629
ORTALAMA	7,557396	6,969708

Çizelge 6.25'te Model 2 ve Model 3 ile elde edilen MAPE değerleri verilmektedir. Lewis (1982)'e göre Model 2 ve Model 3 sırasıyla 7,557396 ve 6,969708 MAPE değerleri ile çok iyi tahmin grubuna girmektedir.

Model 4 = 2008-2013 yılları arasındaki gerçek verilerin Portföy optimizasyon modelinde kullanılması

6.4.2. Modellere ait beklenen getiri, varyans ve kovaryans değerlerinin hesaplanması

Bu veriler kullanılarak her model ve hisse senedi için öncelikle Denklem 6.3'deki formül yardımıyla beklenen getiriler μ_i hesaplanmıştır.

$$\mu_i = \sum_{t=1}^T R_{it}/T, i=1,2,\dots,26 \quad (6.3)$$

burada,

μ_i = i hisse senedinin beklenen getirisi,

R_{it} = i hisse senedinin t dönemindeki dönemlik getirisi,

T = Dönem.

Modelde, amaç fonksiyonunda risk ölçütü olarak kullanılacak varyans değerleri Denklem 6.4 kullanılarak hesaplanmıştır.

$$Cov(R_i, R_j) = \sigma_{ij} = \frac{1}{T} \sum_{t=1}^T (R_{it} - \mu_i) \cdot (R_{jt} - \mu_j), i=1,2,\dots,26; j=1,2,\dots,26, \quad (6.4)$$

Modeller için hesaplanan beklenen getiriler EK 9'da, varyans ve kovaryans değerleri Model 0 için EK 10'da, Model 1 için EK 11'de, Model 2 için EK 12'de, Model 3 için EK 13'te, Model 4 için EK 14'te verilmiştir.

6.4.3. Modellerin tanımlı olduğu enküçük ve enbüyük beklenen getiri değerlerinin hesaplanması

Öncelikle bu modellerin tanımlı ortak beklenen getiri aralığının bulunması amaçlanmıştır. Bu yüzden her modelin enküçük beklenen getiri ve enbüyük beklenen getiri değerleri hesaplanmıştır.

Modellerin enküçük beklenen getirileri Denklem 6.5'deki portföy optimizasyon modeli çözülerek bulunmuştur. Z değeri, enküçük kovaryans değerine karşı gelen beklenen getiri değerini vermektedir.

$$Z = \sum_{i=1}^{26} x_i \mu_i \quad (6.5)$$

$$\sum_{i=1}^{26} x_i = 1$$

$$0 \leq x_i \leq 1, i = 1, \dots, 26$$

k.a.

$$Enk \quad \sum_{i=1}^{26} \sum_{j=1}^{26} x_i x_j \sigma_{ij}$$

Burada,

μ_i : i varlığının beklenen getirisi ($i = 1, \dots, 26$),

σ_{ij} : i ve j varlıkları arasındaki kovaryans değeri ($i = 1, \dots, 26$), ($j = 1, \dots, 26$), $i = j$ için i

varlığının varyans değeri,

Z : Enküçük kovaryans değerine karşı gelen beklenen getiri

x_i : i varlığının portföy içindeki oranı, (karar değişkeni) ($i = 1, \dots, 26$)

Modellere ait enbüyük beklenen getiri değerleri ise Denklem 6.6'daki model çözülerek bulunmuştur. Amaç fonksiyonu değeri enbüyük beklenen getiri değerini vermektedir.

$$\sum_{i=1}^{26} x_i = 1 \quad (6.6)$$

$$0 \leq x_i \leq 1, i = 1, \dots, 26$$

k.a.

$$Enb \quad \sum_{i=1}^{26} x_i \mu_i$$

Örnek olarak, EK 15'te Model 2'nin enküçük beklenen değerini, EK 16'da ise enbüyük beklenen değerini bulmaya yönelik yazılmış lingo kodları bulunmaktadır.

Yukarıda verilen iki matematiksel model lingo programında çözülerek, her modele ilişkin bulunan enküçük ve enbüyük beklenen getiri değerleri Çizelge 6.26'te verilmektedir. Karşılaştırma yapılabilmesi açısından beklenen getiri için ortak bir aralığın bulunması gerekmektedir. Bu aralığın elde etmek için modellere göre elde edilen enküçük beklenen değerlerin enbüyüğü olan 0,01953451 değeri ile enbüyük beklenen getirilerin en enküçük değeri 0,032832 alınmıştır.

Çizelge 6.26. Modellere ait eniyi portföyün enküçük ve enbüyük beklenen getiri değerleri.

Model No	Model	Enküçük Beklenen Getiri	Enbüyük Beklenen Getiri
0	Gerçek Veriler (2014)	0,01953451	0,07722755
1	Üstel	0,00967166	0,07050613
2	YSA LM-BR	0,00016574	0,06790730
3	YSA LM-BR-Üstel	0,00000000	0,07050613
4	Geçmiş Gerçek Veriler (2008-2013)	0,00426000	0,03283200

6.4.4. Modeller için farklı beklenen getiri seviyelerine göre varyansların hesaplanması

Modellere ait etkin sınır grafiklerinin çizilebilmesi için enküçük beklenen getirinin 0,01953451 değerine, enbüyük beklenen getirinin 0,032832 değerine sahip olduğu her modelin tanımlı olduğu alan Denklem 6.7'deki formül kullanılarak 20 eşit aralığa bölünmüştür.

$$\text{Aralık} = \Delta = \frac{\text{Enb getiri} - \text{Enk getiri}}{20} \quad (6.7)$$

$$\Delta = \frac{0,032832 - 0,01953451}{20}$$

$$\Delta = 0,00066487$$

Daha sonra bu aralıklar kullanılarak Çizelge 6.27-6.30'da görülebilen 21 farklı beklenen getiri düzeyi elde edilmiştir.

Bu beklenen getiri düzeyleri ve aşağıdaki matematiksel model kullanılarak modellere ait varyans değerleri hesaplanmıştır.

$$\sum_{i=1}^{26} x_i \mu_i \geq R_t \quad (6.8)$$

$$\sum_{i=1}^{26} x_i = 1$$

$$0 \leq x_i \leq 1, i = 1, \dots, N$$

k.a.

$$\text{Enk} \sum_{i=1}^{26} \sum_{j=1}^{26} x_i x_j \sigma_{ij}$$

Burada,


$$R_t : t. \text{ aralık için hedeflenen beklenen getiri düzeyi, } (R_t = \text{Enk getiri} + t\Delta, t=0,1,\dots,20)$$

Örnek olarak Model 2'nin 0.01953451 beklenen getiri düzeyindeki varyans değerini bulmak amacıyla yazılan lingo kodları EK 17'de verilmiştir.

Üstel Düzeltme modelinin belirlenen beklenen getiri düzeylerindeki varyans değerleri Çizelge 6.27'de verilmiştir. Benzer şekilde Çizelge 6.28'de YSA LM-BR modelinin, Çizelge 6.29'da YSA LM-BR-Üstel modelinin, Çizelge 6.30'da ise Geçmiş Gerçek Veriler modelinin belirlenen beklenen getiri düzeylerindeki varyans değerleri verilmektedir. Ayrıca bu çizelgelerde 2014 yılına ait gerçek verilerin bu belirlenen beklenen getiri düzeylerindeki varyans değerleri ile modeller arasındaki mutlak hataları verilmektedir.

Çizelge 6.27. Model 1'in belirlenen beklenen getiri düzeylerindeki varyans değerleri ve Model 0'a ait varyans değerleri.


Satır No	Beklenen Getiri	Modele 1'e Ait Varyans	Model 0'a Ait Varyans	Mutlak Hata
1	0,01953451	0,000707007	0,000722110	0,0000151034
2	0,02019938	0,000727173	0,000722433	0,0000473930
3	0,02086426	0,000747735	0,000723404	0,0000243306
4	0,02152913	0,000768692	0,000725022	0,0000436698
5	0,02219401	0,000790045	0,000727296	0,0000627498
6	0,02285888	0,000811794	0,000730234	0,0000815602
7	0,02352376	0,000833939	0,000733837	0,0001001020
8	0,02418863	0,000856479	0,000738106	0,0001183730
9	0,02485351	0,000879415	0,000743039	0,0001363760
10	0,02551838	0,000902746	0,000748629	0,0001541170
11	0,02618326	0,000926473	0,000754892	0,0001715820
12	0,02684813	0,000950596	0,000761820	0,0001887770
13	0,02751300	0,000975114	0,000769413	0,0002057020
14	0,02817788	0,001000029	0,000777671	0,0002223590
15	0,02884275	0,001025338	0,000786594	0,0002387440
16	0,02950763	0,001051044	0,000796182	0,0002548620
17	0,03017250	0,001077145	0,000806435	0,0002707100
18	0,03083738	0,001103642	0,000817337	0,0002863050
19	0,03150225	0,001130534	0,000828919	0,0003016150
20	0,03216713	0,001157823	0,000841167	0,0003166560
21	0,03283200	0,001185506	0,000854080	0,0003314270



Şekil 6.7. Model 1'in belirlenen beklenen getiri düzeylerindeki varyans değerleri ve Model 0'a ait varyans değerleri.

Çizelge 6.28. Model 2'nin belirlenen beklenen getiri düzeylerindeki varyans değerleri ve Model 0'a ait varyans değerleri.


Satır No	Beklenen Getiri	Model 2'ye Ait Varyans	Model 0'a Ait Varyans	Mutlak Hata
1	0,01953451	0,00036421	0,000722110	0,00035790
2	0,02019938	0,00037456	0,000722433	0,00034790
3	0,02086426	0,00038563	0,000723404	0,00033780
4	0,02152913	0,00039763	0,000725022	0,00032740
5	0,02219401	0,00041054	0,000727296	0,00031680
6	0,02285888	0,00042438	0,000730234	0,00030590
7	0,02352376	0,00043940	0,000733837	0,00029440
8	0,02418863	0,00045542	0,000738106	0,00028270
9	0,02485351	0,00047244	0,000743039	0,00027060
10	0,02551838	0,00049046	0,000748629	0,00025820
11	0,02618326	0,00050947	0,000754892	0,00024540
12	0,02684813	0,00052953	0,000761820	0,00023230
13	0,02751300	0,00055093	0,000769413	0,00021850
14	0,02817788	0,00057369	0,000777671	0,00020400
15	0,02884275	0,00059782	0,000786594	0,00018880
16	0,02950763	0,00062325	0,000796182	0,00017290
17	0,03017250	0,00064948	0,000806435	0,00015700
18	0,03083738	0,00067629	0,000817337	0,00014100
19	0,03150225	0,00070366	0,000828919	0,00012530
20	0,03216713	0,00073163	0,000841167	0,00010950
21	0,03283200	0,00076027	0,000854080	0,00009381



Şekil 6.8. Model 2'nin belirlenen beklenen getiri düzeylerindeki varyans değerleri ve Model 0'a ait varyans değerleri.

Çizelge 6.29. Model 3'ün belirlenen beklenen getiri düzeylerindeki varyans değerleri ve Model 0'a ait varyans değerleri.


Satır No	Beklenen Getiri	Model 3'e Ait Varyans	Model 0'a Ait Varyans	Mutlak Hata
1	0,01953451	0,000628778	0,000722110	0,000093332
2	0,02019938	0,000650549	0,000722433	0,000071884
3	0,02086426	0,000672730	0,000723404	0,000050674
4	0,02152913	0,000695320	0,000725022	0,000029703
5	0,02219401	0,000718319	0,000727296	0,000089770
6	0,02285888	0,000741724	0,000730234	0,000011490
7	0,02352376	0,000765529	0,000733837	0,000031692
8	0,02418863	0,000789731	0,000738106	0,000051625
9	0,02485351	0,000814330	0,000743039	0,000071291
10	0,02551838	0,000839328	0,000748629	0,000090699
11	0,02618326	0,000864723	0,000754892	0,000109830
12	0,02684813	0,000890515	0,000761820	0,000128700
13	0,02751300	0,000916706	0,000769413	0,000147290
14	0,02817788	0,000943294	0,000777671	0,000165620
15	0,02884275	0,000970279	0,000786594	0,000183690
16	0,02950763	0,000997663	0,000796182	0,000201480
17	0,03017250	0,001025444	0,000806435	0,000219010
18	0,03083738	0,001053638	0,000817337	0,000236300
19	0,03150225	0,001082262	0,000828919	0,000253340
20	0,03216713	0,001111317	0,000841167	0,000270150
21	0,03283200	0,001140802	0,000854080	0,000286720



Şekil 6.9. Model 3'ün belirlenen beklenen getiri düzeylerindeki varyans değerleri ve Model 0'a ait varyans değerleri.

Çizelge 6.30. Model 4'ün belirlenen beklenen getiri düzeylerindeki varyans değerleri ve Model 0'a ait varyans değerleri.

Satır No	Beklenen Getiri	Model 4'e Ait Varyans	Model 0'a Ait Varyans	Mutlak Hata
1	0,01953451	0,006854152	0,000722110	0,006132042
2	0,02019938	0,007026099	0,000722433	0,006303666
3	0,02086426	0,007206834	0,000723404	0,006483430
4	0,02152913	0,007396516	0,000725022	0,006671494
5	0,02219401	0,007595202	0,000727296	0,006867907
6	0,02285888	0,007802865	0,000730234	0,007072631
7	0,02352376	0,008020240	0,000733837	0,007286403
8	0,02418863	0,008249341	0,000738106	0,007511235
9	0,02485351	0,008490360	0,000743039	0,007747321
10	0,02551838	0,008743262	0,000748629	0,007994633
11	0,02618326	0,009008047	0,000754892	0,008253155
12	0,02684813	0,009284674	0,000761820	0,008522854
13	0,02751300	0,009573331	0,000769413	0,008803919
14	0,02817788	0,009874691	0,000777671	0,009097021
15	0,02884275	0,010188880	0,000786594	0,009402286
16	0,02950763	0,010515860	0,000796182	0,009719678
17	0,03017250	0,010855720	0,000806435	0,010049285
18	0,03083738	0,011216270	0,000817337	0,010398933
19	0,03150225	0,011809150	0,000828919	0,010980231
20	0,03216713	0,013712060	0,000841167	0,012870893
21	0,03283200	0,017100850	0,000854080	0,016246771



Şekil 6.10. Model 4'ün belirlenen beklenen getiri düzeylerindeki varyans değerleri ve Model 0'a ait varyans değerleri.

Şekil 6.7, Şekil 6.8, Şekil 6.9 ve Şekil 6.10'da modellere ve 2014 yılının gerçek verilerine ait varyans değerlerinin karşılaştırmalı grafikleri verilmiştir. Grafiklerde yatay eksenler beklenen getirilerin satır numaralarını gösterirken, dikey eksenler modellerin beklenen getiri düzeylerindeki varyanslarını göstermektedir. Grafiklerden de anlaşılacağı üzere, geçmiş verilerin varyans eğrisine en yakın eğriye sahip olan Model 3 olan YSA LM-BR-Üstel Düzeltme modelidir. Bunu izleyen ikinci model ise Üstel Düzeltme Yönteminin tek başına kullanıldığı Model 1'dir.

6.4.5. Modellere ait varyansların gerçek verilere ait varyanslara göre mutlak hatalarının varyans analizi (tek yönlü ANOVA)

Varyans analizi yapılırken kullanılan bağımlı değişken mutlak hatalar iken bağımsız değişken karşılaştırılan modellerdir.

Modellerin varyanslarının gerçek verilerin varyanslarına göre mutlak hatalarının homojenliği Levene Testi yapılarak incelenmiştir.

Çizelge 6.31. Mutlak hata değişkenine göre tanımlayıcı istatistikler.

No	Model	Sayı	Ortalama	Std. Sapma	Std. Hata	Ortalama İçin %95 Güven Aralığı		Enküçük	Enbüyük
						Alt Sınır	Üst Sınır		
1	Mode 1	21	0,00017	0,00010	0,00002	0,00012	0,000217	0,00002	0,00033
2	Model2	21	0,00024	0,00008	0,00001	0,00020	0,000275	0,00009	0,00036
3	Model3	21	0,00013	0,00009	0,00001	0,00009	0,000172	0,00001	0,00029
4	Model4	21	0,00878	0,00243	0,00053	0,00767	0,009888	0,00613	0,01625
Toplam		84	0,00233	0,00393	0,00043	0,00147	0,003184	0,00001	0,01625

Çizelge 6.32. Varyansların homojenliği testi.

Levene İstatistiği	df1	df2	Sig.
22,625	3	80	0,000

Çizelge 6.33. ANOVA sonuçları.

	Karelerin Toplamı	df	Ortalama Kare	F	Sig.
Gruplar Arasında	0,001	3	0,000	261,753	0,000
Gruplar İçerisinde	0,000	80	0,000		
Toplam	0,001	83			

Çizelge 6.33 'te verilmekte olan ANOVA sonuçları incelendiğinde, "Sig." değeri $p = 0,000$ ($p < 0,05$) olduğu için tek yönlü varyans analizi için olan H_0 hipotezi reddedilir. Yani "%95 güvenle, grupların ortalamaları arasında istatistiksel olarak anlamlı bir farklılık vardır." denilebilir.

Gruplar arasında fark var ise; Çizelge 6.32'de görülen varyansların homojenliği testindeki sig.(anlamlılık(p)) değeri incelenir. $p > 0,05$ ise varyanslar homojen dağılmıştır, $p < 0,05$ ise varyanslar homojen dağılmamıştır. $p = 0,000$ ($p < 0,05$) olduğundan varyanslar homojen dağılmamıştır. Bu yorum uygulanacak post-hoc testi belirlemek için kullanılır.

Buraya kadar analizde gruplar arasında beklenen getiri değerleri bakımından fark olduğu ve varyansların homojen dağılmadığı tespit edilmiştir. Post-hoc testi olarak varyansların homojen olmaması halinde yapılacak testlerden "Tamhane's T2" testi yapılmıştır.

Çizelge 6.34. Tamhane Testi çoklu karşılaştırmalar.

Bağımlı Değişken:		Ortalama Fark	Standart Sapma	Sig.
Beklenen Getiri				
1	2	-0,00006740934	0,00002867914	0,136
	3	0,00003705828	0,00002908381	0,757
	4	-0,0086115845*	0,00053104648	0,000
2	1	0,00006740934	0,00002867914	0,136
	3	0,00010446761*	0,00002591531	0,001
	4	-0,0085441751*	0,00053088238	0,000
3	1	-0,00003705828	0,00002908381	0,757
	2	-0,0001044676*	0,00002591531	0,001
	4	-0,0086486428*	0,00053090439	0,000
4	1	0,00861158449*	0,00053104648	0,000
	2	0,00854417514*	0,00053088238	0,000
	3	0,00864864276*	0,00053090439	0,000

Çizelge 6.34'te her grubun ikişerli karşılaştırmaları yapılmış ve bu karşılaştırılan grupların ortalamaları arasındaki farklar (Ortalama Farkı) sayısal olarak verilmiştir. Çizelge incelendiğinde 1-4 (Üstel Düzeltme / Geçmiş Gerçek Veriler (2008-2013)), 2-3 (YSA LM-BR / YSA LM-BR-Üstel), 2-4 (YSA LM-BR / Geçmiş Gerçek Veriler (2008-2013)) ve 3-4 (YSA LM-BR-Üstel / Geçmiş Gerçek Veriler (2008-2013)) ikililerinin yanında bir yıldız(*) işareti olduğu görülür. Yani bu ikililerin ortalamaları arasında anlamlı bir farklılık vardır.

Son olarak, Çizelge 6.31'deki Tanımlayıcı İstatistikler incelendiğinde, YSA LM-BR-Üstel Modeli grubunun varyans değerlerinin gerçek verilerin varyans değerlerinden mutlak farklılığının diğer gruplarınkinden daha küçük olduğu görülmektedir. Yani, YSA LM-BR-Üstel Modelinin Mutlak Hata değerinin, diğer modellerin Mutlak Hata değerlerinden daha düşük olduğu söylenebilir. Bunu izleyen ikinci en düşük model ise Üstel Düzeltme modelidir.

7. SONUÇLAR VE ÖNERİLER

Tahmin yöntemlerinin ve tahmin yöntemlerinden elde edilen sonuçların Portföy Optimizasyonu alanında kullanımının oldukça büyük bir öneme sahip olmasına rağmen, literatürde bu yöntemleri inceleyen ve hangisinin diğerlerine üstünlük gösterdiğini bulmayı amaçlayan kapsamlı çalışmalar az sayıdadır. Bu çalışmanın amacı, zeki tahmin yöntemlerine göre Markowitz'in ortalama-varyans modelinin performansını analiz etmektir. Bu amaçlar doğrultusunda, ilk olarak, çeşitli yöntemlerin tahminleme gücünden yararlanılarak Portföy Optimizasyonu gerçekleştiren çalışmalar incelenmiş olup, bu çalışmalardan Yapay Sinir Ağı Yönteminden faydalanan çalışmalar detaylı olarak ele alınmıştır. Ardından, Yapay Sinir Ağları ile yapılan tahminleme sonucunda, en uygun girdi veri setinin 2014 yılındaki 12 aylık getirilerin tahmin edilmesini sağlayan 2008-2013 yılları arasındaki kapanış değerlerinin olduğu görülmüştür. En uygun girdi değişken sayısı 4 olarak bulunurken, Bayesyen Düzeltme Geri Yayılım öğrenme algoritması Levenberg-Marquardt Geri Yayılım algoritmasından daha iyi tahmin sonuçları sağlamıştır. Buna ek olarak, farklı modellerde, daha iyi performans gösteren saklı katmandaki nöron sayıları farklılık göstermiştir. En iyi performansı sağlayan YSA 5'te en iyi nöron sayısı 10 olarak bulunmuştur. Yapay Sinir Ağları ve Zaman Serileri Analizi Yöntemleri arasında yapılan karşılaştırma çalışmalarında, MAPE ortalamalarından hareketle, Basit Ortalama Yöntemi ve Trend Analizi Yönteminin gerçekten oldukça uzak tahminler verdiği sonucuna ulaşılmıştır. Diğer taraftan, en iyi tahmin performansını $\alpha = 0.9$ katsayısına sahip Üstel Düzeltme Yöntemi verirken, ikinci en iyi yöntem Bayesyen Düzeltme Geri Yayılım Algoritması ile eğitilen saklı katmanda 10 nörona sahip Yapay Sinir Ağları olmuştur. Hareketli Ortalamalar Yöntemi de ortalama hata açısından bakıldığında Üstel Düzeltme ve Yapay Sinir Ağlarına yakın sonuçlar vermiş fakat hisse senedi bazında sadece iki hisse senedinde Üstel düzeltmeye üstün gelirken, söz konusu hisse senetlerinde Yapay Sinir Ağları yöntemi daha iyi tahmin performansı göstermiştir.

Yapay Sinir Ağları (farklı nöron sayıları ve öğrenme algoritmalarını içerecek şekilde) ile Üstel Düzeltme Yöntemlerinin sağladığı tahmin sonuçları hisse senedi bazında incelendiğinde ise, bu iki modelin her hisse senedinde tamamen birbirine üstünlük göstermediği görülmektedir. Bazı hisse senetlerinde Üstel Düzeltme Yöntemi daha iyi tahmin sonucu sağlarken, bazı hisse senetlerinde Levenberg-Marquardt Geri Yayılım Algoritmasına sahip Yapay Sinir Ağı Yöntemi ya da Bayesyen Düzeltme Geri Yayılım öğrenme algoritmasına sahip Yapay Sinir Ağı Yöntemi daha iyi performans göstermiştir. Diğer taraftan, farklı nöron sayıları da performansı etkilemiştir. Bu yüzden, zeki tahmin yöntemlerinin birleştirilerek daha iyi

sonular saėlayacaėı dşnlmştr. Sadece stel Dzeltme Yntemi'nin rettiėi tahminler kullanılarak oluşturulan Model 1'in ortalama MAPE deėeri **7,431500** iken, sadece YSA kullanılarak oluşturulan Model 2'nin ortalama MAPE deėeri **7,557396**, YSA ve stel Dzeltme kullanılarak oluşturulan Model 3'n ortalama MAPE deėeri ise **6,969708**'dir. Lewis (1982)'e gre, MAPE deėerleri %10'un altında olan modelleri ok iyi kabul edildiėi iin bu alıřmada Model 1, Model 2 ve Model 3 ok iyi tahmin edici yntemler olarak gsterilebilir. Bu baėlamda, her bir hisse senesinde en iyi tahmin performansı gsteren yntem seilerek portfyler oluşturulup, sadece gemiř verilere dayalı oluşturulan portfyler ve 2014 yılı verileri ile oluşturulan portfyler ile karřılařtırılmıřtır. Karřılařtırmalar sonucunda, gereėe en yakın sonuları stel Dzeltme Yntemi - Levenberg-Marquardt Geri Yayılım Algoritmasına sahip Yapay Sinir Aėı Yntemi- Bayesyen Dzeltme Geri Yayılım Algoritmasına sahip Yapay Sinir Aėı Yntemi ile oluşturulan portfyn verdiėi grlmřtr.

Sonu olarak, bu alıřmanın literatre ve finans alanına iki aıdan fayda saėlayabileceėi dřnlmektedir. İlk olarak literatr alıřması ıřıėında, Portfy Optimizasyonu analizlerinde kullanılan Yapay Sinir Aėları ve diėer tahmin yntemlerinin sınıflandırılması akademisyenlerin ilgisini ekebilecektir. İkinci olarak, etkin portfyler elde etmek amacıyla, Yapay Sinir Aėları ve stel Dzeltme Yntemi ile oluşturulan tahmine dayalı yeni bir portfy optimizasyonu modelinin kullanımı, arařtırmacılara ve yatırımcılara gl bir finansal ara saėlayacaktır. Bahsedilen faydalarının yanında, bu alıřma ile ilgili sz edilmesi gereken birka sınırlayıcı faktr de bulunmaktadır. İlk olarak, bu alıřmada elde edilebilen veri seti sadece 2008-2014 yılları arasındaki kapanıř deėerlerinden oluřmaktadır. Bunun yerine daha fazla veri veya farklı zaman periyotları iin analiz geniřletilebilir. İkincisi, elde edilen tahmin modellerinin farklı tahmin modelleri ile birleřtirilmesi daha gl tahminler saėlayabilir. ncs, alıřmaya portfyde kullanılacak hisse senetlerinin seimi iin ok ltl karar verme yntemleri entegre edilebilir. Son olarak, bu alıřmaya deney tasarımı da dahil edilmesi daha iyi bir analiz gerekleřtirilmesini saėlayabilir.

KAYNAKLAR DİZİNİ

Architecture Technology Corporation, (1991), Introduction to Neural Networks, Elsevier Advanced Technology, s. 4-7, 19.

Arena, P., Fortuna, L., Muscato, G., Xibilia, M.G., (1998), Neural Networks in Multidimensional Domains: Fundamentals and New Trends in Modelling and Control, Springer, s. 3-4.

Ataseven, B., (2013), Yapay Sinir Ağları ile Öngörü Modellemesi, Dergipark 10:39, s. 101-115.

Ayan, T.Y., Akay, A., (2013), Tahmine Dayalı Portföy Optimizasyonu: Modern Portföy Teorisinde Risk ve Beklenen Getiri Kavramlarına Alternatif Bir Yaklaşım, Dumlupınar Üniversitesi Sosyal Bilimler Dergisi EYİ 2013 Özel Sayısı.

Ayvaz, B., (2013), İstatistik ve Olasılık I Ders Notları, İstanbul Ticaret Üniversitesi Endüstri Mühendisliği Bölümü, s. 11.

Bishop, C. M., (1995), Neural Networks for Pattern Recognition, Oxford, Oxford University Press.

Brockwell, P.J., Davis, R.A., (1996), Introduction to Time Series and Forecasting, Springer, s. 1-2, 24.

Carpenter, G. A., Grossberg, S., (1988), The ART of Adaptive Pattern Recognition by a Self-Organising Neural Network, Computer, s. 77-88.

Cartwright, H.M., (2009), Artificial Neural Networks: Methods and Applications, Humana Press, s. 16.

Ceylan, A., Korkmaz, T., (1998), Borsada Uygulamalı Portföy Yönetimi, Ekin Yayınevi.

Chase Jr., C.W., (2009), Demand Driven Forecasting: A Structured Approach to Forecasting, Wiley & Sons, s. 112.

Civan, M., (2007), Sermaye Piyasası Analizleri ve Portföy Yönetimi, Gazi Kitapevi, s.305.

Corner, D., Mayes, D.G., (1983), Modern Portfolio Theory and Financial Institutions, Macmillan Publishers, s. 2.

Çalışkan, M.M.T., Deniz, D. (2015), Yapay Sinir Ağlarıyla Hisse Senedi Fiyatları ve Yönlerinin Tahmini, Eskişehir Osmangazi Üniversitesi İİBF Dergisi 10(3), s. 177- 194.

Çolak, E., (2015), Biyoistatistik Ders Notları, Eskişehir Osmangazi Üniversitesi.

Çuhadar, M., Kayacan, C., (2005), Yapay Sinir Ağları Kullanılarak Konaklama İşletmelerinde Doluluk Oranı Tahmini: Türkiye'deki Konaklama İşletmeleri Üzerine Bir Deneme, Anatolia: Turizm Araş. Der. 16(1), s.24-30.

KAYNAKLAR DİZİNİ (devam)

Czibula, G., Czibula, I.G., Găceanu, R.D., (2013), Intelligent Data Structures Selection Using Neural Networks, Knowl Inf Syst 34, s. 171–192.

Çalışkan, M. M. T., Deniz, D., (2015), Yapay Sinir Ağlarıyla Hisse Senetleri Tahminleri ve Yapay Sinir Ağlarıyla Hisse Senetleri Tahminleri ve Yönlerinin Tahmini, Eskişehir Osmangazi Üniversitesi İİBF Dergisi, 10(3), s. 177-194.

Dağlı, H., (2004), Sermaye Piyasası ve Portföy Analizi, Derya Kitabevi.

Dangi, A., (2012), Financial Portfolio Optimization: Computationally guided agents to investigate, analyse and invest!?, A thesis submitted for the degree of Master of Technology, University of Pune, s. 10.

Davalo, E., Naım, P., (1991), Neural Networks, Macmillan Education, s. 3.

Detienne, K. B., Detienne D. H., Joshi, S. A., (2003), Neural Networks As Statistical Tools For Business Researchers. Organizational Research Methods, 6(2), s. 236-265.

Diebold, F.X., (2006), Elements of Forecasting, Thomson South-Western, s. 260.

Diler, A.İ. (2003), İMKB Ulusal-100 Endeksinin Yönünün Yapay Sinir Ağlarıyla Hata Geriye Yayma Yöntemi İle Tahmin Edilmesi, İMKB Dergisi 7, s. 25-26, 65-81.

Donaldson, R.G., Kamstra, M., (1996), Forecast Combining With Neural Networks, J Forecast 15(1), s. 49–61.

Doymuş, K., (2008), Varyans Analizi Ders Notları, Atatürk Üniversitesi, s. 1-4.

Dreyfus, G., (2005), Neural Networks methodology and Applications, Springer, s. 105.

Duqi, A., Franci, L., Torluccio, G., (2014), The Black–Litterman Model: The Definition of Views Based on Volatility Forecasts, Applied Financial Economics 24 (19), s. 1285-1296.

Ercan, M.K., Ban, Ü., (2008), Değere Dayalı İşletme Finansı, Finansal Yönetim, Gazi Kitabevi, s.188.

Eren, B., Eyüpoğlu, V., (2011), Yapay Sinir Ağları İle Ni(II) İyonu Geri Kazanım Veriminin Modellenmesi, 6th International Advanced Technologies Symposium (IATS'11), s. 188.

Fabozzi, F.J., Gupta, F., Markowitz, H.M., (2002), The Legacy of Modern Portfolio Theory, Journal of Investing 11(3), s. 8.

Fabozzi, F.J., Kolm, P.N., Pachamanova, D.A., Focardi, S.M., (2007), Robust Portfolio Optimization and Management, John Wiley & Sons, Inc, s. 23, 116.

KAYNAKLAR DİZİNİ (devam)

Fabozzi, F.J., Markowitz, H.M., (2011), The Theory and Practice of Investment Management: Asset Allocation, Valuation, Portfolio Construction, and Strategies, John Wiley & Sons, Inc, s. 6-9.

Fausett, L., (1994), Fundamentals of Neural Networks: Architectures, Algorithms and Applications, Prentice Hall, s. 5-6, 17, 59.

Fernandes, B., Street, A., Valladão, D., Fernandes, C., (2016), An Adaptive Robust Portfolio Optimization Model With Loss Constraints Based on Data-Driven Polyhedral Uncertainty Sets, *European Journal of Operational Research* 000, s. 1–10.

Flores, J.A., (2011), Focus on Artificial Neural Networks, Nova Science Publishers, s. 174-177.

Foresee, F.D., Hagan, M.T., (1997), Gauss-Newton Approximation to Bayesian Learning, *Proceedings of the International Joint Conference on Neural Networks*.

Freitas, F.D., De Souza, A.F., de Almeida, A.R., (2009), Prediction-based Portfolio Optimization Model Using Neural Networks, *Neurocomputing* 72, s. 2155-2170.

Frechtling, D.C., (2001), Forecasting Tourism Demand: Methods and Strategies, Butterworth-Heinemann, s. 24-28.

Fulga, C., (2016), Portfolio Optimization With Disutility-Based Risk Measure, *European Journal of Operational Research* 251, s. 541–553.

Fyfe, C., (2000), Artificial Neural Networks and Information Theory, The University of Paisley, s. 10-11, 39-40.

Gately, E., (1998), Forecasting Profits Using Price & Time, Wiley & Sons, s. 13, 130-131.

Gohout, W., Specht, K., (2007), Mean-Variance Portfolios Using Bayesian Vector-Autoregressive Forecasts, *Statistical Papers* 48, s. 403-418.

Goldberg, D. E., (1989), Genetic Algorithms in Search, Optimisation and Machine Learning, Addison-Wesley.

Gökgöz, E., (2006), Riske Maruz Değer (VaR) ve Portföy Optimizasyonu, Sermaye Piyasası Kurulu s. 64.

Graupe, D., (1997), Principles of Artificial Neural Networks, World Scientific Publishing Co. Pte. Ltd., s. 1.

Gupta, P., Mehlawat, M.K., Inuiguchi, M., Chandra, S., (2014), Fuzzy Portfolio Optimization: Advances in Hybrid Multi-criteria Methodologies, Springer, s. 1.

KAYNAKLAR DİZİNİ (devam)

Gunasekaran, M., Ramaswami, K.S., (2014), A Hybrid Intelligent System of ANFIS and CAPM For Stock Portfolio Optimization, *Journal of Intelligent & Fuzzy Systems* 26, s. 277–286.

Gülle, A.Ö., (2016), Lojistik Yönetimi Ders Notları, İstanbul Üniversitesi, Ulaştırma ve Lojistik Fakültesi.

Gülpınar, N., Rustem, B., (2007), Worst–Case Robust Decisions for Multi-Period Mean-Variance Portfolio Optimization, *European Journal of Operational Research* 183, s. 981-1000.

Gülten, S., Rusczyński, A., (2015), Two-Stage Portfolio Optimization With Higher-Order Conditional Measures of Risk, *Annals of Operations Research* 229, s. 409-427.

Hagan, M.T., Demuth, H.B., Beale, M.H., Jesús, O.D., (2014), Neural Network Design, Martin Hagan, s. 1-5,7;7-1.

Hajek, M., (2005), Neural Networks, University of KwaZulu-Natal, s.11-14.

Hamid, S. A., Iqbal Z. (2004), Using Neural Networks for Forecasting Volatility of S&P 500 Index Futures Prices, *Journal of Business Research*, 57, s. 1119.

Haykin, S., (1999), Neural Networks: A Comprehensive Foundation, Prentice Hall International, Inc., s. 1-2, 60-61.

Haykin, S., (2008), Neural Networks and Learning Machines, Pearson Prentice Hall, s. 2-5, 10-11, 35-37, 371.

Hecht-Nielsen, R., (1990,) Neurocomputing, Addison-Wesley, Reading, MA.

Hill, R.A., (2010), Portfolio Theory & Financial Analyses, Ventus Publishing, s. 42-43.

Holden, K., Peel, D.A., Thompson, J.L., (1990), Economic Forecasting: An Introduction, Cambridge University Press, s. 35-37.

Holland, J. H., (1975), Adaptation in Natural and Artificial Systems, University of Michigan Press.

Hopfield J., (1982), Neural Networks and Physical Systems With Emergent Collective Computational Abilities. *Proceedings of The National Academy of Sciences of the United States of America* 79, s. 2554-2558.

Hristev, R.M., (1998), The ANN Book, Academic Press, s. 218-219.

Hsu, C.M., (2014), An Integrated Portfolio Optimisation Procedure Based on Data Envelopment Analysis, Artificial Bee Colony Algorithm and Genetic Programming, *International Journal of Systems Science* 45.

KAYNAKLAR DİZİNİ (devam)

http://bm.bilecik.edu.tr/Dosya/Icerik/107/DosyaEki/nsg_ders_notu.pdf, Erişim Tarihi: Haziran 2016.

<http://www.datastore.borsaistanbul.com>, Erişim Tarihi: Ekim 2015.

<http://www.finansofisi.com/yeni-finans-yuksek-frekansli-alim-satim-islemleri-hft/>, Erişim Tarihi: Haziran 2017.

<http://www.ibrahimcayiroglu.com/Dokumanlar/IleriAlgoritmaAnalizi/IleriAlgoritmaAnalizi-5.Hafta-YapaySinirAglari.pdf>, Erişim Tarihi: Ocak 2017.

<http://www.istanbul.edu.tr/muh/endustri/lojistik/wp-content/uploads/TalepTahminYontemleri.pdf>, Erişim Tarihi: Mart 2012.

<http://kanalfinans.com/editor/milisaniyelik-yatirimci>, Erişim Tarihi: Haziran 2017.

<http://volkaniset.blogspot.com.tr/p/spssone-way-anovatek-yonlu-varyans.html>, Erişim Tarihi: Kasım 2016.

Indro, D.C. vd., (1999), Predicting Mutual Fund Performance Using Artificial Neural Networks, *Omega* 27(3), s. 373–380.

İskenderoğlu, Ö., Karadeniz, E., (2011), Optimum Portföy Seçimi: İMKB 30 Üzerinde Bir Uygulama, *C.Ü. İktisadi ve İdari Bilimler Dergisi* 12, s. 236-237.

Jain, A.K., Mao, J., (1996), Artificial Neural Networks: A Tutorial, *IEEE*, s. 35-38.

Jakobs, B.I., Levy, K.N., Markowitz, H.M., (2005), Portfolio Optimization with Factors, Scenarios and Realistic Short Positions, *Operations Research*, 53(4), s. 586.

Kacapyr, E., (1996), Economic Forecasting : The State of the Art, ME Sharpe, Inc., s. 155.

Kanal, L.N., Rosenfeld, A., (1991), Artificial Neural Networks and Statistical Pattern Recognition: Old and New Connections, Elsevier Science Publishers, s. 13.

Karaatlı, M., Helvacıoğlu, Ö.C., Ömürbek, N., Tokgöz, G., (2012), Yapay Sinir Ağları Yöntemi İle Otomobil Satış Tahmini, *Uluslararası Yönetim İktisat ve İşletme Dergisi* 8, s. 4.

Karan, M.B., (2001), Yatırım Analizi ve Portföy Yönetimi, Gazi Kitabevi.

Karayiannis, N.B., Venetsanopoulos, A.N., (1993), Artificial Neural Networks: Learning Algorithms, Performance Evaluation, and Applications, Springer, s. 21-22.

Kartalopoulos, S. V., (1996), Understanding Neural Network and Fuzzy Logic, IEEE Press, s. 46.

KAYNAKLAR DİZİNİ (devam)

Kasabov, N.K., (1996), Foundations of Neural Networks, Fuzzy Systems and Knowledge Engineering, The MIT Press, s. 251-264, 301.

Kim, K., (2003), Financial Time Series Forecasting Using Support Vector Machines, *Neurocomputing* 55, s. 307-309.

Kohonen, T. (1989), Self-Organisation and Associative Memory, Springer-Verlag.

Kohonen, T., Makisara, K., Saramaki, T.,(1984), Phonotopic Mapsinsightful Representation of Phonological Features For Speech Recognition, Proc. 7th Int. Conf on Pattern Recognition.

Kolb, W.R., Rodriguez J.R., (1992) Finansal Yönetim, SPK Yayınları 35.

Kröse, B., Smagt, P.V.D., (1996), An Introduction to Neural Networks, The University of Amsterdam, s. 18.

Kuligowski, R.J., Barros, A.P., (1998), Experiments in Short-Term Precipitation Forecasting Using Artificial Neural Networks, *Mon Weather Rev* 126, s. 470–482.

Kumar, K., Bhattacharya, S., (2006), Artificial Neural Network vs. Linear Discriminant Analysis in Credit Ratings Forecast: A Comparative Study of Prediction Performances, *Review of Accounting and Finance* 5(3), s. 216–227.

Lancaster, G.A., Lomas, L.A., (1985), Forecasting for Sales and Materials Management, Macmillan Publishers Ltd., s. 37-38, 68, 82-86, 97, 129-137.

Law, R., (2000), Back-Propagation Learning in Improving The Accuracy of Neural Network-Based Tourism Demand Forecasting, *Tour Manag* 21(4), s. 331–340.

Leung, P.L., Ng, H.Y., Wong, W.K., (2012), An Improved Estimation to Make Markowitz's Portfolio Optimization Theory Users Friendly and Estimation Accurate With Application on the US Stock Market Investment, *European Journal of Operational Research* 222, s. 85-95.

Levenberg, K., (1944), A Method For The Solution of Certain Problems in Least Squares., *Quart. Applied Mathematics* 2, s. 164–168.

Lewis, C.D, (1982), Industrial and Business Forecasting Methods, Butterworths Publishing, London, s. 40.

Lewis, C.D., (1997), Demand Forecasting and Inventory Control, Woodhead Publishing Ltd, s. 3-6, 27, 55.

Lintner, J., (1965), Security Prices, Risk, and Maximal Gains From Diversification, *The Journal of Finance* 20(4), s. 587–615.

KAYNAKLAR DİZİNİ (devam)

Livingstone, D.J., (2009), Artificial Neural Networks: Methods and Applications, Humana Press, s. 15.

Lossen, U., (2007), Portfolio Strategies of Private Equity Firms: Theory and Evidence, Deutscher Universitäts-Verlag, s. 18.

Luo, C., Seco, L., Wu, L.L.B., (2015), Portfolio Optimization in Hedge Funds by OGARCH and Markov Switching Model, *Omega* 57, s. 34-39.

Makridakis, S.G., Wheelwright, S.C., Hyndman, R.J., (1997), Forecasting Methods and Applications, Wiley & Sons, s. 539.

Makridakis, S., Wheelwright, S. C., Hyndman, R. J. (1998), Forecasting: Methods and Applications, 3rd edition, Wiley, s. 49-50.

Mansini, R., Ogryczak, W., Speranza, M.G., (2015), Linear and Mixed Integer Programming for Portfolio Optimization, Springer, s. 1-4, 21.

Markowitz, H., (1952), Portfolio Selection, *Journal of Finance* 7, s. 77-91.

Markowitz, H.M., (1959), Portfolio Selection, Efficient Diversification of Investments, John Wiley & Sons, Inc.

Markowitz, H.M., (1999), The Early History of Portfolio Theory: 1600-1960, *Financial Analysts Journal* (July/August), s. 5–16.

Marquardt, D. W., (1963), An Algorithm For Least-Squares Estimation of Nonlinear Parameters., *Journal of the Society of Industrial Applied Mathematics* 11, s. 431– 441.

Masters, T., (1995), Advanced Algorithms for Neural Networks: A C++ Sourcebook, John Wiley & Sons.

Matmoura, Y., Penev, S., (2013), Multistage Optimization of Option Portfolio Using Higher Order Coherent Risk Measures, *European Journal of Operational Research* 227, s. 190-198.

Mcfall, K.S., (2006), An Artificial Neural Network Method For Solving Boundary Value Problems With Arbitrary Irregular Boundaries, Ph.D. thesis, Georgia Institute of Technology.

Mehrotra, K., Mohan, C.K., Ranka, S., (1997), Elements of Artificial Neural Networks, MIT Press, s. 5-8, 14, 43-44, 80, 94, 188, 250.

Mendes, R.R.A., Paiva, A.P., R.S.Peruchi, Balestrassi, P.P., Leme, R.C., Silva, M.B., (2016), Multiobjective Portfolio Optimization of ARMA–GARCH Time Series Based on Experimental Designs, *Computers & Operations Research* 66, s. 434–444.

KAYNAKLAR DİZİNİ (devam)

Michaud, R.O., Michaud, R.O, (2008), Efficient Asset Management: A Practical Guide to Stock Portfolio Optimization and Asset Allocation, Oxford University Press, s. 3-8.

Mishra, S.K., Panda, G., Majhi, B., (2016), Prediction Based Mean-Variance Model For Constrained Portfolio Assets Selection Using Multiobjective Evolutionary Algorithms, *Swarm and Evolutionary Computation* 28, s. 117–130.

Montana, D.J., Davis, L., (1989), Training Feed Forward Neural Networks Using Genetic Algorithms, in *Proceedings of The 11th International Joint Conference on Artificial Intelligence* 1, s. 762–767.

Moon, M.A., (2013), Demand and Supply Integration The Key to World-Class Demand Forecasting, FT Press, s. 103.

Müller, B., Reinhardt, J., Strickland, M.T., (1995), Neural Networks: An Introduction, Springer, s. 3, 18.

Nugus, S., (2005), Financial Planning using Excel: Forecasting Planning and Budgeting Techniques, CIMA Publishing, s. 5-6, 26, 32-33.

Özalp, A., Anagün, A.S., (2001), Sektörel Hisse Senedi Fiyat Tahmininde Yapay Sinir Ağı Yaklaşımı ve Klasik Tahminleme Yöntemleri ile Karşılaştırılması, *Endüstri Mühendisliği Dergisi* 12:3-4, s. 8-10.

Öztemel, E., (2003), Yapay Sinir Ağları, Papatya Yayınları, s. 76-77.

Öztemel, E., (2012), Yapay Sinir Ağları, Papatya Yayınları, s. 26, 31-33, 48-49.

Palamutçuoğlu, B.T., (2014), Üretim Yönetimi Ders Notları, Celal Bayar Üniversitesi Kula Meslek Yüksekokulu, s. 38-39.

Pan, X., Lee, B., Zhang, C., (2013), A Comparison of Neural Network Backpropagation Algorithms for Electricity Load Forecasting, *Intelligent Energy Systems (IWIES), IEEE International Workshop on*, s. 22-27.

Palit, A.K., Popovic, D., (2005), Computational Intelligence in Time Series Forecasting: Theory and Engineering Applications, Springer, s. 49-51.

Pekkaya, M., Albayrak, A.S., (2013), ARFIMA ve FIGARCH Yöntemlerinin Markowitz Ortalama Varyans Portföy Optimizasyonunda Kullanılması: İMKB-30 Endeks Hisseleri Üzerine Bir Uygulama, *İstanbul Üniversitesi İşletme Fakültesi Dergisi* 42 (1), s. 93-112.

Pham, D.T., Karaboga, D., (2000), Intelligent Optimisation Techniques: Genetic Algorithms, Tabu Search, Simulated Annealing and Neural Networks, Springer, s. 18-25.

Priddy, K.L., Keller, P.E., (2005), Artificial Neural Networks: An Introduction, SPI Publications, s. 4-9, 119-122.

KAYNAKLAR DİZİNİ (devam)

Rabunal, J.R., Dorado, J., (2005), Artificial Neural Networks in Real-life Applications, Idea Group Publishing, s. 358.

Rachev, S.T., Stoyanov, S.V., Fabozzi, F.J., (2008), Advanced Stochastic Models, Risk Assessment, and Portfolio Optimization: The Ideal Risk, Uncertainty, and Performance Measures, John Wiley & Sons, Inc, s. 245.

Ranković, V., Drenovak, M., Urosevic, B., Jelic, R., (2016), Mean-Univariate GARCH VaR Portfolio Optimization: Actual Portfolio Approach, *Computers & Operations Research* 72, s. 83–92.

Reidmiller, M., Braun, H., (1993), A Direct Adaptive Method for Faster Back Propagation Learning: The RPROP Algorithm, in *Proceedings of the IEEE International Conference on Neural Networks*, s. 586–591.

Ruan, D., (1997), Intelligent Hybrid Systems: Fuzzy Logic, Neural Networks and Genetic Algorithms, Kluwer Academic Publishers, s. 12-13, 140-141.

Rumelhart, D. E., McClelland, J. L., (1986), Parallel Distributed Processing: Explorations in the Microstructure of Cognition, MIT Press.

Samonas, M., (2015), Financial Forecasting, Analysis, and Modelling: A Framework for Long-Term Forecasting, Wiley & Sons, s. 89.

Sexton, R.S., Gupta, J.N.D., (2000), Comparative Evaluation of Genetic Algorithm and Back Propagation for Training Neural Networks, *Inf. Sci.* 129, s. 45–59.

Shao, B.P., Rachev, S.T., Mu, Y., (2015), Applied Mean-ETL Optimization in Using Earnings Forecasts, *International Journal of Forecasting* 31, s. 561-567.

Sharpe, W.F., (1964), Capital Asset Prices: A Theory of Market Equilibrium Under Conditions of Risk, *The Journal of Finance* 19(3), s. 425–442.

Siddique, N., Adeli, H., (2013), Computational Intelligence: Synergies of Fuzzy Logic, Neural Networks and Evolutionary Computing, Wiley & Sons, s. 127-136, 464.

Singh, P., (2016), Applications of Soft Computing in Time Series Forecasting Simulation and Modeling Techniques, Springer, s. 22-23.

Steiner, M., Wittkemper, H.G., (1997), Portfolio Optimization With A Neural Network Implementation of The Coherent Market Hypothesis, *European Journal of Operational Research* 100 (1997), s. 27-40.

Tay, F.E.H., Cao, L., (2001), Application of Support Vector Machines in Financial Time Series Forecasting, *Omega* 29, s. 310.

KAYNAKLAR DİZİNİ (devam)

Taylor, J.W, Buizza, R., (2002), Neural Network Load Forecasting With Weather Ensemble Predictions, IEEE Trans Power Syst 17, s. 626–632.

Terzic, E., Terzic, J., Nagarajah, R., Alamgir, M., (2012), A Neural Network Approach to Fluid Quantity Measurement in Dynamic Environments, Springer, s. 45-49.

Tiwari, S., Naresh, R., Jha, R., (2013), Comparative Study of Backpropagation Algorithms in Neural Networks Based Identification of Power System, International Journal of Computer Science & Information Technology (IJCSIT) 5, s. 101.

Travers, F.J., (2004), Investment Manager Analysis: A Comprehensive Guide to Portfolio Selection, Monitoring and Optimization, John Wiley & Sons, Inc, s. 78-79.

Ulucan, A., (2004), Portföy Optimizasyonu, Siyaset Kitabevi, s. 9-19.

Unger, A., (2015), The Use of Risk Budgets in Portflio Optimization, Springer Gabler, s. 13.

Üstün, Ö., Kasimbeyli, R., (2012), Combined Forecasts in Portfolio Optimization: A Generalized Approach, Computers & Operations Research, 39 (4), s. 805-819.

Widrow, B., Hoff, M.E., (1960), Adaptive Switching Circuits, Proc, IRE WESCON Convention Record, s. 96-104.

Wilson, I.D., Paris, S.D., Ware, J.A., Jenkins, D.H., (2002), Residential Property Price Time Series Forecasting With Neural Networks, Knowl-Based Syst 15(5–6), s. 335–341.

Witt,S.F,Witt, C., (1992), Modeling and Forecasting Demand in Tourism, Academic Press: London, s. 137.

Wright, M., Robbie, K., (1998), Venture Capital and Private Equity: A Review and Synthesis, Journal of Business Finance & Accounting 25(June/July), s. 521–570.

Xidonas, P., Mavrotas, G., Krintas, T., Psarras, J., Zopounidis, C., (2012), Multicriteria Portfolio Management, Springer, s. 6-7.

Yadav, N., Yadav, A., Kumar, M., (2015), An Introduction to Neural Network Methods for Differential Equations, Springer, s. 19-26, 35-39.

Yavuz, A., (2013), Zaman Serisi Analizleri, Ders Notları, s. 3-15.

Yue, Z., Songzheng Z., Tianshi, L., (2011), Bayesian Regularization BP Neural Network Model for Predicting Oil-Gas Drilling Cost, Business Management and Electronic Information (BMEI), International Conference on 2, s. 483,487.

Zhou, X., Nakajima, J., West, M., (2014), Bayesian Forecasting and Portfolio Decisions Using Dynamic Dependent Sparse Factor Models, International Journal of Forecasting 30, s. 963-980.

EKLER

- EK 1.** 2008-2012 yılları arası Yapay Sinir Ağı uygulaması performans sonuçları.
- EK 2.** 2008-2013 yılları arası Yapay Sinir Ağı uygulaması performans sonuçları.
- EK 3.** 2008-2014 yılları arası Yapay Sinir Ağı uygulaması performans sonuçları.
- EK 4.** 2008-2014 yılları arası (6 ay) Yapay Sinir Ağı uygulaması performans sonuçları.
- EK 5.** 2008-2014 yılları arası (4 ay) Yapay Sinir Ağı (Bayesyen Düzeltme Geri Yayılım) uygulaması performans sonuçları.
- EK 6.** Üstel Düzeltme Yöntemi α katsayısına göre MAPE sonuçları.
- EK 7.** MAPE değerleri kullanılarak Model 2 için yöntemlerin seçilmesi.
- EK 8.** MAPE değerleri kullanılarak Model 3 için yöntemlerin seçilmesi.
- EK 9.** Portföy Optimizasyonunda modeller için hesaplanan beklenen getiriler.
- EK 10.** Portföy Optimizasyonu Analizinde Model 0 için hesaplanan varyans-kovaryans matrisi.
- EK 11.** Portföy Optimizasyonu Analizinde Model 1 için hesaplanan varyans-kovaryans matrisi.
- EK 12.** Portföy Optimizasyonu Analizinde Model 2 için hesaplanan varyans-kovaryans matrisi.
- EK 13.** Portföy Optimizasyonu Analizinde Model 3 için hesaplanan varyans-kovaryans matrisi.
- EK 14.** Portföy Optimizasyonu Analizinde Model 4 için hesaplanan varyans-kovaryans matrisi.
- EK 15.** Model 2'nin minimum beklenen değerini bulmaya yönelik yazılmış Lingo Programı kodları
- EK 16.** Model 2'nin maksimum beklenen değerini bulmaya yönelik yazılmış Lingo Programı kodları.
- EK 17.** Model 2'nin 0,01953451 beklenen getiri düzeyindeki minimum varyans değerini bulmak amacıyla yazılan Lingo Programı kodları.

EK 1. 2008-2012 yılları arası Yapay Sinir Ağı uygulaması performans sonuçları.

Hisse Senedi	Nöron Sayısı	MSE	MAE	MAPE	Training	Validation	Test	All
AKBANK	5	0,024181	0,131323	28,08321	0,91382	0,76177	0,84879	0,89392
	10	0,021864	0,115189	19,84250	0,91893	0,84023	0,88095	0,89415
	15	0,024892	0,132724	27,78015	0,84562	0,97749	0,92354	0,82687
	20	0,017623	0,111771	22,40898	0,93598	0,83288	0,76620	0,86620
AKSA	5	0,003543	0,039473	5,972920	0,96212	0,95846	0,88299	0,95722
	10	0,013191	0,106719	15,21131	0,98000	0,91998	0,86636	0,96306
	15	0,003956	0,048340	7,182635	0,94632	0,97368	0,79142	0,94292
	20	0,004127	0,052770	7,635514	0,93926	0,99370	0,86067	0,93832
ARÇELİK	5	0,020852	0,113859	15,03827	0,92459	0,96075	0,97759	0,93617
	10	0,090545	0,198427	25,00472	0,96255	0,89942	0,94239	0,95118
	15	0,033864	0,147071	19,29020	0,97512	0,97719	0,83968	0,95255
	20	0,087158	0,208623	26,49581	0,98147	0,97800	0,91038	0,96344
ASYA KATILIM BANKASI	5	0,000917	0,024689	12,70549	0,90863	0,98892	0,81772	0,83121
	10	0,002228	0,036325	19,15299	0,81385	0,97129	0,76168	0,81360
	15	0,001092	0,016380	9,090346	0,94128	0,92682	0,61978	0,82493
	20	0,001438	0,028612	15,09521	0,99048	0,91891	0,74770	0,96870
BİM MAĞAZALAR	5	0,015980	0,078106	16,47624	0,98239	0,83454	0,94762	0,96625
	10	0,037334	0,148801	31,65894	0,93278	0,81786	0,66306	0,90407
	15	0,010929	0,070770	15,07031	0,88333	0,93579	0,62968	0,72947
	20	0,007270	0,064939	13,79119	0,90021	0,89207	0,92663	0,89427
DOĞAN HOLDİNG	5	0,008894	0,080572	29,37528	0,95726	0,89300	0,86065	0,91109
	10	0,029725	0,095777	37,75464	0,61958	0,74952	0,71773	0,64044
	15	0,018942	0,094209	37,92510	0,91311	0,95450	0,62452	0,87599
	20	0,014743	0,079855	30,32498	0,90961	0,88874	0,95542	0,90999
ENKA İNŞAAT	5	0,002858	0,045502	26,99689	0,98194	0,98413	0,78156	0,97879
	10	0,009867	0,060346	43,38344	0,95873	0,78369	0,96745	0,95119
	15	0,008941	0,060980	42,87136	0,94630	0,94197	0,78627	0,91140
	20	0,005250	0,041346	29,61595	0,97994	0,96996	0,55851	0,94750
EREĞLİ DEMİR ÇELİK	5	0,004739	0,045187	30,05194	0,91313	0,49460	0,91936	0,79227
	10	0,005525	0,052752	40,07349	0,95339	0,96271	0,75956	0,90536
	15	0,033035	0,158101	128,4531	0,96932	0,85405	0,72648	0,88598
	20	0,006654	0,057872	44,68231	0,86607	0,79718	0,82353	0,80429
GARANTİ BANKASI	5	0,005595	0,064402	9,605769	0,91237	0,73492	0,97593	0,90783
	10	0,014557	0,103554	15,62077	0,91739	0,98825	0,81758	0,91953
	15	0,015496	0,110022	16,37661	0,96668	0,84207	0,76726	0,90123
	20	0,008105	0,071177	10,76925	0,93217	0,80265	0,90800	0,91125
İHLAS HOLDİNG	5	0,021746	0,126702	26,18150	0,91557	0,96342	0,96970	0,92835
	10	0,005033	0,064998	13,80852	0,92938	0,83398	0,96507	0,90513
	15	0,006920	0,071831	14,72881	0,88849	0,94059	0,79421	0,88433
	20	0,006272	0,062530	13,55531	0,98405	0,75958	0,95938	0,94885
İŞ BANKASI	5	0,034706	0,154706	38,51718	0,80241	0,88068	0,68253	0,80463
	10	0,036569	0,158630	38,55136	0,67648	0,90294	0,82390	0,72749
	15	0,042347	0,164568	44,25969	0,75712	0,65780	0,60126	0,70932
	20	0,030011	0,136581	35,51794	0,76079	0,75221	0,70128	0,73296
KARDEMİR	5	0,020648	0,117698	20,71082	0,95617	0,91682	0,55513	0,88210
	10	0,055715	0,155278	22,12327	0,91891	0,97074	0,81675	0,90474
	15	0,017739	0,107104	16,86376	0,97565	0,93993	0,62953	0,93835
	20	0,015392	0,107592	17,20770	0,91481	0,84862	0,64780	0,87557
KOÇ HOLDİNG	5	0,013903	0,079731	10,81743	0,94429	0,96440	0,81418	0,92362
	10	0,029006	0,154139	22,29786	0,95897	0,89977	0,92395	0,93713
	15	0,015822	0,100904	14,02153	0,96107	0,87538	0,90822	0,94386
	20	0,012238	0,084131	12,44655	0,94377	0,96795	0,96387	0,94103

EK 1. 2008-2012 yılları arası Yapay Sinir Ağı uygulaması performans sonuçları (devamı).

Hisse Senedi	Nöron Sayısı	MSE	MAE	MAPE	Training	Validation	Test	All
PETKİM	5	0,001894	0,034026	29,57417	0,81647	0,98885	0,99097	0,85530
	10	0,003407	0,026210	23,58339	0,99697	0,85440	0,87445	0,92153
	15	0,003583	0,033806	30,42650	0,97626	0,99463	0,98342	0,97788
	20	0,000508	0,014428	11,72202	0,87778	0,99936	0,90900	0,90908
SABANCI	5	0,016364	0,088302	11,67709	0,89100	0,92919	0,93081	0,90319
	10	0,036786	0,162668	23,06036	0,93207	0,98572	0,98633	0,95578
	15	0,086052	0,211353	27,26058	0,94828	0,87095	0,86927	0,91446
	20	0,018083	0,104351	14,21298	0,92367	0,93258	0,72023	0,90423
SİNPAŞ	5	0,000997	0,021094	15,69941	0,74047	0,93558	0,83846	0,80470
	10	0,006941	0,057068	41,78096	0,92194	0,97158	0,86379	0,92346
	15	0,011991	0,076453	55,78370	0,96686	0,62550	0,90340	0,91896
	20	0,004665	0,028649	22,03721	0,87030	0,85828	0,70254	0,85998
ŞİŞE CAM	5	0,011059	0,089089	16,70957	0,95913	0,98194	0,97729	0,96554
	10	0,038911	0,164173	31,87061	0,89500	0,92853	0,87384	0,88510
	15	0,020486	0,111179	21,11592	0,81921	0,92854	0,99940	0,86150
	20	0,011441	0,087583	16,13573	0,95539	0,98098	0,95373	0,95305
T. HALK BANKASI	5	0,010294	0,076322	10,20272	0,870955	0,98424	0,99142	0,92100
	10	0,021655	0,119615	15,37716	0,95732	0,96709	0,89833	0,94495
	15	0,112571	0,252098	32,07233	0,91046	0,94456	0,84073	0,90508
	20	0,02046	0,116207	15,40289	0,96080	0,94506	0,94854	0,95191
TEKFEN	5	0,004542	0,049500	9,334940	0,92943	0,88710	0,63862	0,88436
	10	0,007757	0,073579	13,80216	0,96208	0,99556	0,70311	0,88569
	15	0,011621	0,086333	16,25721	0,91833	0,91325	0,93911	0,91019
	20	0,014987	0,097357	18,82069	0,98154	0,90228	0,98316	0,95550
TOFAŞ	5	0,009006	0,083407	11,72905	0,94704	0,98128	0,99088	0,94902
	10	0,016548	0,105132	14,15767	0,96137	0,97747	0,90793	0,95468
	15	0,014148	0,099686	13,79400	0,97693	0,98943	0,90929	0,96223
	20	0,013469	0,096967	14,28547	0,96189	0,95853	0,97569	0,95345
TURKCELL	5	0,044824	0,161589	29,06177	0,73574	0,91609	0,97504	0,78811
	10	0,067944	0,214690	39,08690	0,87729	0,92752	0,94113	0,88195
	15	0,046550	0,185046	33,30266	0,79262	0,74981	0,91109	0,80122
	20	0,024343	0,112230	23,58723	0,90519	0,87523	0,53868	0,83068
TÜPRAŞ	5	0,008664	0,076454	10,79482	0,91569	0,97601	0,98301	0,93599
	10	0,009532	0,078530	11,14703	0,98855	0,91194	0,79875	0,93494
	15	0,013063	0,089100	14,10182	0,99276	0,94442	0,92203	0,96288
	20	0,007618	0,073522	10,97787	0,92680	0,81817	0,93478	0,91246
TÜRK HAVA YOLLARI	5	0,007290	0,058733	26,64956	0,84373	0,95544	0,95331	0,73547
	10	0,002787	0,039759	13,65709	0,87440	0,98371	0,71204	0,88400
	15	0,009077	0,058434	27,11454	0,85103	0,79436	0,89527	0,83751
	20	0,006517	0,051965	26,11696	0,91711	0,98916	0,87881	0,92300
TÜRK TRAKTÖR	5	0,010198	0,071132	11,07540	0,98592	0,99256	0,97575	0,98454
	10	0,006744	0,061550	10,14189	0,98868	0,97009	0,98844	0,98248
	15	0,006789	0,063354	10,02201	0,97385	0,98013	0,94276	0,95753
	20	0,017358	0,095308	15,61939	0,99123	0,98419	0,96631	0,98128
VAKIFLAR BANKASI	5	0,009823	0,084851	12,90649	0,97847	0,86081	0,67778	0,94550
	10	0,017965	0,113540	17,74593	0,91905	0,96261	0,82044	0,92200
	15	0,017913	0,115232	17,97791	0,96408	0,84264	0,85452	0,92120
	20	0,009578	0,078198	11,17683	0,96042	0,84778	0,95691	0,94844
YAPI VE KREDİ BANK	5	0,017250	0,102876	21,15231	0,89167	0,98427	0,95526	0,90812
	10	0,008170	0,077888	15,33156	0,95889	0,82656	0,87952	0,93423
	15	0,019538	0,123950	24,54761	0,96211	0,76544	0,88693	0,93388
	20	0,011898	0,089479	16,21648	0,93002	0,91739	0,91020	0,92350

EK 2. 2008-2013 yılları arası Yapay Sinir Ağı uygulaması performans sonuçları.

Hisse Senedi	Nöron Sayısı	MSE	MAE	MAPE	Training	Validation	Test	All
AKBANK	5	0,011062	0,084733	14,15917	0,80418	0,91589	0,82352	0,81772
	10	0,010887	0,091097	14,70543	0,80891	0,77872	0,80030	0,80406
	15	0,009672	0,079858	13,17636	0,73445	0,81146	0,88629	0,76005
	20	0,008413	0,076677	12,46219	0,88619	0,89007	0,53058	0,80665
AKSA	5	0,089439	0,250358	32,39758	0,94015	0,98224	0,98462	0,95535
	10	0,102892	0,271820	35,27690	0,98569	0,96083	0,89479	0,97057
	15	0,184126	0,377606	50,15312	0,97262	0,91007	0,89310	0,95976
	20	0,162821	0,327396	41,76169	0,96003	0,99530	0,95632	0,96589
ARÇELİK	5	0,006028	0,063692	7,887653	0,96117	0,96515	0,95377	0,96056
	10	0,004453	0,055272	7,021277	0,97039	0,96073	0,96081	0,96738
	15	0,016813	0,115713	14,27748	0,95598	0,98941	0,88872	0,95717
	20	0,102706	0,277606	34,96140	0,98152	0,97162	0,93390	0,96961
ASYA KATILIM BANKASI	5	0,000466	0,016697	8,850939	0,92824	0,90863	0,91836	0,92689
	10	0,000692	0,019578	10,37035	0,97492	0,98226	0,88034	0,95727
	15	0,000498	0,017069	8,899788	0,95080	0,89620	0,97865	0,92667
	20	0,000511	0,017004	8,957330	0,79841	0,90296	0,99098	0,81953
BİM MAĞAZALAR	5	0,010627	0,069913	28,54000	0,91251	0,98567	0,96754	0,93069
	10	0,019930	0,102708	39,78955	0,75795	0,97450	0,98172	0,78884
	15	0,013754	0,063386	26,02113	0,85937	0,97274	0,89077	0,87156
	20	0,024990	0,088087	39,99932	0,98003	0,89915	0,51251	0,92981
DOĞAN HOLDİNG	5	0,003407	0,048440	13,36025	0,96574	0,89452	0,82288	0,93150
	10	0,002613	0,042138	11,29188	0,94131	0,89523	0,72689	0,89721
	15	0,003739	0,051734	13,04276	0,86907	0,91676	0,51394	0,81087
	20	0,004779	0,058327	15,30920	0,94730	0,93768	0,59834	0,90343
ENKA İNŞAAT	5	0,002127	0,034072	15,52862	0,94294	0,86690	0,85502	0,87701
	10	0,003255	0,045618	20,49467	0,96456	0,98996	0,93079	0,95479
	15	0,001712	0,030335	13,61390	0,96117	0,97432	0,84011	0,95499
	20	0,003299	0,048150	20,59075	0,96764	0,64099	0,95140	0,94331
EREĞLİ DEMİR ÇELİK	5	0,000529	0,019906	13,84659	0,91546	0,68525	0,71765	0,89275
	10	0,000616	0,021441	14,65225	0,94798	0,96557	0,98920	0,94766
	15	0,000324	0,015353	11,64727	0,94610	0,78258	0,96733	0,91121
	20	0,001069	0,026735	21,80531	0,87980	0,81893	0,89798	0,86538
GARANTİ BANKASI	5	0,026095	0,141008	18,94528	0,96380	0,94819	0,78925	0,93267
	10	0,005852	0,066285	9,061698	0,93832	0,90321	0,93364	0,93199
	15	0,010147	0,085303	12,25347	0,91312	0,95911	0,89021	0,91912
	20	0,053601	0,199059	25,77721	0,92596	0,96939	0,96786	0,93376
İHLAS HOLDİNG	5	0,006463	0,058009	18,19171	0,85827	0,94613	0,97382	0,88390
	10	0,008190	0,080032	26,58212	0,88671	0,79072	0,97948	0,87735
	15	0,013786	0,103405	32,67176	0,88155	0,89240	0,97244	0,88123
	20	0,006666	0,058590	17,89761	0,88672	0,89523	0,98400	0,89762
İŞ BANKASI	5	0,022395	0,127855	21,26616	0,64151	0,79629	0,57940	0,65386
	10	0,016018	0,114617	17,55138	0,65489	0,55612	0,81933	0,67094
	15	0,069946	0,224235	33,21675	0,81227	0,78903	0,74468	0,79375
	20	0,046287	0,180530	27,97700	0,66284	0,60173	0,82853	0,67560
KARDEMİR	5	0,019280	0,110374	20,81239	0,87057	0,82927	0,92937	0,88037
	10	0,032116	0,151512	29,41682	0,93560	0,89977	0,93214	0,93009
	15	0,040503	0,176629	32,39942	0,86364	0,98526	0,92799	0,90033
	20	0,065130	0,231675	41,77460	0,94375	0,99667	0,80351	0,92492
KOÇ HOLDİNG	5	0,016199	0,105609	13,01121	0,92781	0,93834	0,97440	0,93528
	10	0,019077	0,116893	14,96575	0,95862	0,88645	0,92732	0,93155
	15	0,009334	0,075746	9,285510	0,95814	0,92897	0,88296	0,94332
	20	0,004613	0,061615	7,830486	0,94320	0,97297	0,85275	0,94759

EK 2. 2008-2013 yılları arası Yapay Sinir Ağı uygulaması performans sonuçları (devamı).

Hisse Senedi	Nöron Sayısı	MSE	MAE	MAPE	Training	Validation	Test	All
PETKİM	5	0,000211	0,009864	5,139041	0.87576	0.97372	0.93748	0.90636
	10	0,000925	0,024425	12,37828	0.98278	0.99136	0.90858	0.97453
	15	0,000376	0,014111	7,309714	0.96098	0.61932	0.99020	0.89243
	20	0,000367	0,016898	9,268654	0.79869	0.97435	0.79796	0.8684
SABANCI	5	0,007155	0,068094	9,197754	0.93613	0.88955	0.86109	0.91957
	10	0,020621	0,109244	14,61098	0.92505	0.88279	0.87702	0.91763
	15	0,013026	0,096241	13,99818	0.86447	0.96453	0.98426	0.90886
	20	0,008497	0,074714	10,78838	0.90673	0.85238	0.93630	0.90593
SİNPAŞ	5	0,001262	0,030313	21,90112	0.89337	0.97253	0.86919	0.87953
	10	0,000773	0,018302	14,47291	0.75213	0.98361	0.64673	0.80037
	15	0,000502	0,015378	11,89083	0.86748	0.61967	0.89404	0.88691
	20	0,001061	0,023434	18,04378	0.84251	0.98832	0.79831	0.84886
ŞİŞE CAM	5	0,001378	0,029436	5,330497	0.95637	0.90960	0.92427	0.94116
	10	0,015034	0,102322	18,42456	0.98075	0.93128	0.93045	0.96614
	15	0,005987	0,063109	11,52923	0.93180	0.94470	0.95568	0.93544
	20	0,001874	0,033978	6,105414	0.96759	0.93048	0.8255	0.946
T. HALK BANKASI	5	0,010330	0,087684	12,35898	0.93201	0.98658	0.90574	0.93012
	10	0,016226	0,100751	15,72447	0.96542	0.96325	0.82335	0.9324
	15	0,018451	0,111842	14,93328	0.92458	0.85362	0.96597	0.9259
	20	0,019919	0,114594	17,46408	0.96037	0.90762	0.85624	0.93747
TEKFEN	5	0,008403	0,068339	14,92730	0.79088	0.94897	0.91371	0.84947
	10	0,022599	0,114782	25,64892	0.96658	0.92263	0.91064	0.95022
	15	0,017585	0,103050	22,12387	0.95594	0.92579	0.92849	0.9484
	20	0,029091	0,137686	27,15946	0.80542	0.98034	0.97139	0.88366
TOFAŞ	5	0,006399	0,071121	8,673911	0.94464	0.91522	0.98753	0.95036
	10	0,044436	0,188465	23,23235	0.97220	0.97086	0.95418	0.96708
	15	0,140797	0,319591	38,83116	0.97151	0.96406	0.96553	0.9682
	20	0,271808	0,489269	60,42437	0.96911	0.96911	0.92346	0.96499
TURKCELL	5	0,018326	0,112238	15,57870	0.60296	0.76021	0.63304	0.61542
	10	0,134413	0,308873	39,45440	0.77310	0.79982	0.77232	0.79306
	15	0,137694	0,333847	42,40943	0.60208	0.52998	0.71875	0.60013
	20	0,125770	0,344423	43,94578	0.71548	0.54976	0.65411	0.66836
TÜPRAŞ	5	0,039000	0,157111	22,93398	0.96725	0.88364	0.64746	0.88519
	10	0,010004	0,087813	12,56381	0.90697	0.99185	0.97215	0.92335
	15	0,033987	0,168803	22,99808	0.92868	0.87640	0.98364	0.93464
	20	0,097883	0,266498	35,18126	0.93349	0.86040	0.95824	0.92999
TÜRK HAVA YOLLARI	5	0,145350	0,296177	40,39311	0.78251	0.95054	0.56576	0.78287
	10	0,040875	0,154043	21,87725	0.65645	0.78718	0.85598	0.72337
	15	0,222167	0,413171	55,64903	0.89645	0.76104	0.90942	0.8793
	20	0,073305	0,225723	30,01719	0.89808	0.93540	0.52406	0.8274
TÜRK TRAKTÖR	5	0,102490	0,218154	26,89057	0.97853	0.98984	0.96917	0.97285
	10	0,008772	0,073446	9,689266	0.98694	0.99080	0.99642	0.98864
	15	0,201614	0,416370	50,54585	0.99739	0.98807	0.97741	0.99169
	20	0,118168	0,306349	37,48891	0.98889	0.98906	0.99118	0.98861
VAKIFLAR BANKASI	5	0,214095	0,405943	59,24033	0.91265	0.97729	0.98483	0.92734
	10	0,013661	0,097767	14,34598	0.89320	0.93696	0.97732	0.91349
	15	0,234334	0,428521	60,79713	0.94040	0.79064	0.89533	0.92223
	20	0,039938	0,178791	27,65930	0.85308	0.92285	0.91409	0.86108
YAPI VE KREDİ BANK	5	0,013749	0,093393	14,08457	0.93295	0.77946	0.93506	0.92536
	10	0,007265	0,053569	8,373729	0.92827	0.91338	0.87772	0.90006
	15	0,020535	0,121494	17,55916	0.95761	0.95800	0.67812	0.92535
	20	0,025619	0,126636	17,81518	0.91394	0.95532	0.89175	0.91359

EK 3. 2008-2014 yılları arası Yapay Sinir Ağı uygulaması performans sonuçları.

Hisse Senedi	Nöron Sayısı	MSE	MAE	MAPE	Training	Validation	Test	All
AKBANK	5	0,010847	0,088538	16,20098	0.84263	0.78420	0.94610	0.83418
	10	0,019837	0,107062	22,32602	0.76361	0.89198	0.74914	0.75770
	15	0,028429	0,135256	27,96632	0.98237	0.89508	0.71665	0.91124
	20	0,006894	0,070621	13,47736	0.82250	0.91701	0.77998	0.82332
AKSA	5	0,003531	0,048305	6,144097	0.97036	0.96738	0.91430	0.96301
	10	0,014678	0,114952	15,15743	0.98492	0.98157	0.89509	0.96114
	15	0,025614	0,124459	15,99547	0.90308	0.94975	0.98025	0.92883
	20	0,002477	0,040860	5,432309	0.97061	0.95239	0.98568	0.97241
ARÇELİK	5	0,003021	0,044831	5,772462	0.98085	0.94975	0.96389	0.97242
	10	0,009209	0,083329	11,02714	0.97472	0.97108	0.98431	0.97199
	15	0,003087	0,048368	6,204232	0.97787	0.95918	0.87412	0.96086
	20	0,005145	0,053528	6,659340	0.97482	0.97854	0.98294	0.97788
ASYA KATILIM BANKASI	5	0,001559	0,033204	26,27042	0.79160	0.91926	0.85960	0.80617
	10	0,001092	0,027793	21,63355	0.75900	0.97973	0.91667	0.79643
	15	0,000766	0,022721	17,35132	0.97724	0.91045	0.95964	0.97234
	20	0,001123	0,025335	20,69958	0.97672	0.77725	0.95874	0.96459
BİM MAĞAZALAR	5	0,000520	0,017673	8,384474	0.93178	0.83150	0.98184	0.91582
	10	0,000762	0,023172	10,69907	0.92482	0.84767	0.88498	0.89345
	15	0,000699	0,019262	9,196684	0.97077	0.93473	0.95288	0.96203
	20	0,000607	0,020284	9,213545	0.72479	0.96278	0.86956	0.74934
DOĞAN HOLDİNG	5	0,001966	0,035369	13,62904	0.89634	0.84698	0.88006	0.88026
	10	0,001741	0,034211	14,01708	0.90664	0.73293	0.85777	0.86931
	15	0,001192	0,027030	11,43286	0.94274	0.81309	0.93547	0.91663
	20	0,004070	0,045439	17,27491	0.89051	0.94995	0.78141	0.89569
ENKA İNŞAAT	5	0,000550	0,018368	7,623972	0.96450	0.97657	0.73990	0.95052
	10	0,001361	0,029931	13,26095	0.97005	0.98807	0.77731	0.96955
	15	0,000809	0,024574	10,39368	0.97503	0.73198	0.97768	0.97078
	20	0,000818	0,023279	8,962322	0.96189	0.86868	0.93427	0.95360
EREĞLİ DEMİR ÇELİK	5	0,001849	0,031537	11,67302	0.94463	0.95719	0.75497	0.87787
	10	0,002351	0,035717	13,28640	0.94296	0.80119	0.95465	0.87061
	15	0,001055	0,025626	9,745594	0.93609	0.97163	0.96463	0.94035
	20	0,002876	0,039426	15,07545	0.95697	0.95993	0.89285	0.93205
GARANTİ BANKASI	5	0,011516	0,089457	12,48963	0.91667	0.94786	0.93838	0.92248
	10	0,008337	0,077157	11,22527	0.89685	0.88304	0.88610	0.89323
	15	0,012220	0,090100	13,91599	0.98396	0.95780	0.89335	0.96433
	20	0,007145	0,077039	11,18768	0.96288	0.86610	0.82955	0.93009
İHLAS HOLDİNG	5	0,001340	0,032232	21,52325	0.86777	0.90011	0.95117	0.88699
	10	0,001189	0,031038	20,34263	0.88761	0.96067	0.89269	0.88469
	15	0,000517	0,018762	11,91409	0.91469	0.84877	0.85149	0.87374
	20	0,000996	0,026262	17,48202	0.90654	0.97431	0.89225	0.90345
İŞ BANKASI	5	0,020375	0,126973	25,37186	0.77683	0.78807	0.69086	0.75660
	10	0,022633	0,123359	22,40109	0.89930	0.82423	0.51526	0.83804
	15	0,023412	0,133133	24,77040	0.90737	0.57888	0.67206	0.82205
	20	0,022152	0,140366	27,22532	0.64847	0.86563	0.91764	0.73711
KARDEMİR	5	0,060149	0,191383	26,88249	0.91915	0.99260	0.91991	0.92656
	10	0,119688	0,291198	40,53963	0.97858	0.96911	0.81688	0.94288
	15	0,035067	0,135420	21,03663	0.95928	0.88107	0.91405	0.94187
	20	0,021065	0,109079	15,90946	0.94584	0.94640	0.82394	0.90551
KOÇ HOLDİNG	5	0,011874	0,094675	12,49917	0.95861	0.96570	0.93471	0.95528
	10	0,003969	0,058280	8,256979	0.97412	0.96075	0.85361	0.94684
	15	0,007739	0,067394	10,31438	0.97492	0.91237	0.93766	0.95741
	20	0,006497	0,066909	9,166399	0.96832	0.98828	0.79728	0.96104

EK 3. 2008-2014 yılları arası Yapay Sinir Ağı uygulaması performans sonuçları (devamı).

Hisse Senedi	Nöron Sayısı	MSE	MAE	MAPE	Training	Validation	Test	All
PETKİM	5	0,000389	0,015375	7,676375	0,97792	0,98237	0,97986	0,94892
	10	0,000725	0,023558	10,89772	0,97125	0,99082	0,99401	0,97599
	15	0,000391	0,016756	8,198735	0,81234	0,98813	0,82799	0,85920
	20	0,000754	0,024498	11,35588	0,84666	0,94887	0,99322	0,87713
SABANCI	5	0,003835	0,046093	7,174807	0,95636	0,94548	0,95506	0,94806
	10	0,012044	0,090825	14,18400	0,97439	0,96315	0,74197	0,94011
	15	0,007591	0,072989	11,38406	0,95718	0,88833	0,96037	0,93922
	20	0,003825	0,049161	7,524254	0,94584	0,95253	0,95733	0,95249
SİNPAŞ	5	0,001324	0,034043	28,93091	0,81454	0,91040	0,89347	0,83050
	10	0,000137	0,009390	8,355732	0,95129	0,87340	0,96876	0,93503
	15	0,000199	0,011414	10,10910	0,99547	0,94985	0,94125	0,91871
	20	0,002837	0,052459	43,66327	0,78849	0,87708	0,95871	0,81735
ŞİŞE CAM	5	0,003853	0,057034	10,55507	0,93961	0,94223	0,91877	0,93616
	10	0,006124	0,059201	10,88372	0,94184	0,95317	0,96996	0,94412
	15	0,012262	0,088830	16,49614	0,98357	0,90066	0,92344	0,95902
	20	0,004323	0,054319	9,310781	0,95668	0,91943	0,86940	0,93579
T. HALK BANKASI	5	0,007265	0,068015	12,01088	0,96788	0,83233	0,93811	0,95538
	10	0,013969	0,107402	18,21237	0,93073	0,98820	0,94554	0,93872
	15	0,014348	0,099577	16,63929	0,90560	0,97171	0,90238	0,92449
	20	0,005075	0,057737	9,407320	0,94763	0,97802	0,95138	0,95211
TEKFEN	5	0,001736	0,035782	9,276215	0,94504	0,89598	0,90567	0,92677
	10	0,001715	0,035244	8,889726	0,94251	0,95478	0,89870	0,94303
	15	0,003161	0,045255	10,89666	0,92287	0,84162	0,92512	0,90527
	20	0,001469	0,033770	8,562646	0,89484	0,93098	0,98169	0,92197
TOFAŞ	5	0,006480	0,065976	8,814226	0,96339	0,97370	0,98054	0,96673
	10	0,007609	0,062131	8,352209	0,98145	0,97869	0,97496	0,98016
	15	0,004224	0,047897	6,786380	0,98237	0,97125	0,88645	0,96489
	20	0,021406	0,096248	12,87572	0,98260	0,96585	0,97511	0,97751
TURKCELL	5	0,009229	0,071453	9,466673	0,73014	0,83736	0,92892	0,78092
	10	0,024356	0,129439	16,54246	0,86677	0,89195	0,65842	0,81029
	15	0,011699	0,082898	10,97978	0,86967	0,90970	0,93936	0,88073
	20	0,179059	0,354712	47,13673	0,97995	0,70404	0,82792	0,88720
TÜPRAŞ	5	0,011830	0,094389	12,56831	0,90421	0,95759	0,97172	0,92277
	10	0,007560	0,073971	10,14454	0,94750	0,92852	0,97450	0,94884
	15	0,008834	0,071077	9,211715	0,98084	0,87381	0,88367	0,95474
	20	0,012191	0,086761	11,75205	0,96654	0,79668	0,91109	0,93474
TÜRK HAVA YOLLARI	5	0,010292	0,069150	9,536087	0,81994	0,97781	0,91905	0,84117
	10	0,010311	0,080689	11,74119	0,81795	0,90625	0,95922	0,83734
	15	0,005060	0,060777	9,396529	0,74406	0,89879	0,78659	0,79164
	20	0,008619	0,072944	11,00038	0,95139	0,91270	0,74046	0,91199
TÜRK TRAKTÖR	5	0,008485	0,081923	10,32747	0,98594	0,98936	0,99761	0,98879
	10	0,008805	0,084156	10,64127	0,98779	0,97262	0,94553	0,97843
	15	0,006751	0,075891	9,837238	0,95298	0,98984	0,96849	0,96074
	20	0,018531	0,114623	14,11059	0,98510	0,99095	0,98822	0,98669
VAKIFLAR BANKASI	5	0,007691	0,067391	12,33696	0,88020	0,97490	0,91094	0,90109
	10	0,010832	0,091259	15,38367	0,94726	0,83154	0,86010	0,90455
	15	0,012677	0,092766	15,69609	0,95610	0,94982	0,79597	0,94578
	20	0,010054	0,078968	13,91640	0,92453	0,77550	0,95706	0,91578
YAPI VE KREDİ BANK	5	0,008259	0,067924	12,43649	0,88409	0,90966	0,93160	0,89656
	10	0,009724	0,085699	13,81048	0,88102	0,95916	0,93664	0,90210
	15	0,013944	0,092925	16,29138	0,94672	0,92602	0,77147	0,92005
	20	0,011886	0,084433	14,37755	0,86991	0,95372	0,97320	0,89360

EK 4. 2008-2014 yılları arası (6 ay) Yapay Sinir Ağı uygulaması performans sonuçları.

Hisse Senedi	Nöron Sayısı	MSE	MAE	MAPE	Training	Validation	Test	All
AKBANK	5	0,014487	0,098007	19,46393	0.85178	0.90754	0.78158	0.85062
	10	0,018461	0,109510	21,37806	0.91504	0.71010	0.83713	0.88224
	15	0,013450	0,103731	19,75854	0.89191	0.81923	0.91851	0.87241
	20	0,029372	0,151304	29,57318	0.99593	0.71381	0.62956	0.89721
AKSA	5	0,014699	0,115117	15,18952	0.98774	0.96831	0.94827	0.97799
	10	0,005816	0,068883	9,109083	0.96687	0.96606	0.93845	0.96265
	15	0,011013	0,096571	12,78638	0.97813	0.91400	0.97735	0.97132
	20	0,005363	0,063134	8,065510	0.96868	0.99649	0.91580	0.97644
ARÇELİK	5	0,017175	0,116105	14,38568	0.96217	0.96098	0.90439	0.95424
	10	0,003657	0,046886	6,091191	0.98739	0.96611	0.96639	0.98194
	15	0,003413	0,045206	5,726116	0.97640	0.99071	0.97847	0.97823
	20	0,009335	0,078046	10,41914	0.98290	0.98076	0.90682	0.96563
ASYA KATILIM BANKASI	5	0,012641	0,098372	61,54266	0.94564	0.93060	0.94451	0.94166
	10	0,004275	0,054547	32,33643	0.97226	0.92239	0.95030	0.96036
	15	0,006364	0,070907	41,23320	0.95124	0.91036	0.97997	0.94391
	20	0,006265	0,070002	41,39999	0.98033	0.97112	0.94026	0.96955
BİM MAĞAZALAR	5	0,002225	0,035094	13,07872	0.82793	0.96708	0.96199	0.86117
	10	0,001290	0,030387	10,15694	0.82375	0.93339	0.98097	0.84500
	15	0,002634	0,042394	13,65251	0.75714	0.97243	0.74663	0.80749
	20	0,002698	0,043656	15,39242	0.82442	0.94487	0.96548	0.86495
DOĞAN HOLDİNG	5	0,003363	0,052267	22,17477	0.86515	0.86428	0.88143	0.86129
	10	0,003376	0,048974	19,74258	0.92674	0.70667	0.65945	0.82953
	15	0,005649	0,055820	23,45718	0.95908	0.90322	0.77868	0.89402
	20	0,002213	0,037403	15,12847	0.92972	0.79314	0.73860	0.88481
ENKA İNŞAAT	5	0,000957	0,024854	9,141934	0.80867	0.73933	0.99642	0.89635
	10	0,000886	0,024907	9,757214	0.90092	0.93196	0.73593	0.88604
	15	0,001057	0,026187	9,383145	0.71292	0.96439	0.95870	0.89345
	20	0,001196	0,027772	11,26629	0.93765	0.92916	0.88449	0.91744
EREĞLİ DEMİR ÇELİK	5	0,002659	0,041439	15,37957	0.96514	0.98634	0.95773	0.96397
	10	0,003033	0,048192	17,63992	0.97280	0.98620	0.86958	0.96269
	15	0,003388	0,046761	17,15194	0.98621	0.93618	0.82048	0.97113
	20	0,003888	0,056205	20,67028	0.99096	0.89449	0.76355	0.82612
GARANTİ BANKASI	5	0,007071	0,069540	9,984287	0.95776	0.97061	0.92225	0.95374
	10	0,006383	0,064672	9,951550	0.95963	0.93182	0.83108	0.95047
	15	0,003786	0,048979	6,803849	0.84672	0.84130	0.98536	0.87787
	20	0,011882	0,083647	11,78824	0.98274	0.90710	0.95975	0.95960
İHLAS HOLDİNG	5	0,000316	0,014377	9,037113	0.92303	0.93420	0.96867	0.92206
	10	0,000431	0,015681	9,770790	0.94914	0.97753	0.90998	0.94701
	15	0,000696	0,018744	11,68183	0.95914	0.88000	0.90733	0.93204
	20	0,000346	0,014480	9,137257	0.98112	0.88046	0.91837	0.94667
İŞ BANKASI	5	0,033883	0,150924	29,05773	0.88154	0.64911	0.71890	0.84674
	10	0,024022	0,131476	24,84519	0.84227	0.71155	0.71147	0.80339
	15	0,025756	0,147087	28,07363	0.78204	0.90454	0.79070	0.79726
	20	0,025899	0,135950	23,52858	0.70722	0.80663	0.86358	0.75511
KARDEMİR	5	0,013834	0,093493	16,07021	0.91298	0.94492	0.81878	0.87319
	10	0,009984	0,091462	15,15647	0.90761	0.95806	0.98082	0.91387
	15	0,090290	0,245314	38,00631	0.98724	0.98417	0.83245	0.97425
	20	0,027839	0,133631	19,98939	0.95757	0.96599	0.80571	0.93521
KOÇ HOLDİNG	5	0,004042	0,049476	6,626801	0.97508	0.99005	0.93682	0.97012
	10	0,005917	0,067326	9,194396	0.97162	0.95716	0.98877	0.96269
	15	0,009274	0,080603	11,51351	0.99747	0.97826	0.83590	0.95505
	20	0,009361	0,075543	10,04370	0.98218	0.98296	0.92803	0.97035

EK 4. 2008-2014 yılları arası (6 ay) Yapay Sinir Ağı uygulaması performans sonuçları (devamı).

Hisse Senedi	Nöron Sayısı	MSE	MAE	MAPE	Training	Validation	Test	All
PETKİM	5	0,000393	0,015290	7,477541	0,99065	0,90132	0,95285	0,96230
	10	0,000927	0,026274	11,83589	0,82111	0,98637	0,96479	0,86496
	15	0,000657	0,021779	10,87650	0,75013	0,98255	0,96739	0,81435
	20	0,000558	0,018435	8,658994	0,95942	0,98976	0,94930	0,96042
SABANCI	5	0,007191	0,065959	10,60502	0,93600	0,94355	0,94060	0,93281
	10	0,003449	0,043961	6,666167	0,94914	0,93228	0,91040	0,94339
	15	0,004486	0,054012	8,374142	0,92635	0,91128	0,97026	0,93355
	20	0,009793	0,071162	11,95045	0,95171	0,96599	0,74915	0,94563
SİNPAŞ	5	0,000563	0,021686	18,55930	0,90314	0,87496	0,97648	0,90489
	10	0,000121	0,008748	7,423302	0,98293	0,96309	0,97075	0,96537
	15	0,000155	0,010320	9,083749	0,97448	0,88592	0,99176	0,95488
	20	0,000251	0,013760	11,72559	0,99623	0,97972	0,94921	0,98247
ŞİŞE CAM	5	0,004822	0,064872	11,55033	0,97698	0,93056	0,87451	0,95360
	10	0,003998	0,056453	10,05559	0,95541	0,86762	0,96395	0,94837
	15	0,014952	0,104800	19,97763	0,92904	0,87804	0,93122	0,91796
	20	0,006400	0,073557	13,15577	0,98103	0,79824	0,94481	0,93637
T. HALK BANKASI	5	0,010762	0,088287	14,26794	0,90674	0,95777	0,97112	0,92508
	10	0,016425	0,104010	17,97414	0,97969	0,90981	0,92809	0,95831
	15	0,012789	0,095405	16,18381	0,97259	0,96727	0,80361	0,93818
	20	0,011975	0,074002	11,73693	0,97726	0,97946	0,84136	0,96391
TEKFEN	5	0,002305	0,043415	9,265663	0,95392	0,84058	0,98606	0,9352
	10	0,004629	0,056547	12,27996	0,99474	0,93997	0,73369	0,95833
	15	0,002924	0,046558	10,14997	0,95805	0,85042	0,83745	0,91334
	20	0,003668	0,044690	10,12550	0,98218	0,89748	0,80322	0,95479
TOFAŞ	5	0,014162	0,075849	10,40093	0,97097	0,98919	0,84122	0,94870
	10	0,008483	0,079968	10,38527	0,97268	0,97114	0,88337	0,96473
	15	0,007552	0,063739	8,442365	0,98756	0,98548	0,91185	0,97856
	20	0,008000	0,073971	9,707381	0,98765	0,92463	0,96602	0,97605
TURKCELL	5	0,040323	0,142438	18,57473	0,85580	0,95620	0,87817	0,87098
	10	0,037410	0,168919	22,17225	0,86041	0,98046	0,71458	0,85822
	15	0,012954	0,092218	12,46774	0,86775	0,86173	0,69918	0,81944
	20	0,009505	0,083315	11,61890	0,88711	0,64411	0,68664	0,84641
TÜPRAŞ	5	0,046577	0,180583	23,02840	0,91637	0,94544	0,96624	0,92014
	10	0,017284	0,101727	13,50577	0,97074	0,93783	0,97924	0,96787
	15	0,007004	0,074238	10,31410	0,98695	0,93365	0,81600	0,95949
	20	0,005383	0,057478	8,263128	0,95917	0,98235	0,93905	0,96048
TÜRK HAVA YOLLARI	5	0,026001	0,110677	15,38340	0,92959	0,97966	0,85128	0,92562
	10	0,013006	0,088798	13,23219	0,78430	0,87159	0,93687	0,81028
	15	0,031458	0,123628	17,21595	0,89759	0,88081	0,87950	0,85900
	20	0,020992	0,098474	13,69548	0,85178	0,94297	0,80160	0,86037
TÜRK TRAKTÖR	5	0,009151	0,081060	10,76320	0,98212	0,98440	0,97785	0,97918
	10	0,016932	0,112610	13,84873	0,96282	0,97187	0,99062	0,96123
	15	0,009880	0,089850	11,30482	0,99270	0,95603	0,99633	0,98516
	20	0,024995	0,134863	16,42753	0,99268	0,94091	0,94534	0,97942
VAKIFLAR BANKASI	5	0,009321	0,081516	13,72965	0,96026	0,86246	0,86823	0,92242
	10	0,023452	0,123151	19,78361	0,96520	0,92912	0,70296	0,92344
	15	0,006980	0,068990	11,75126	0,97620	0,87683	0,90417	0,95877
	20	0,016213	0,106595	19,45005	0,86355	0,92838	0,87183	0,87389
YAPI VE KREDİ BANK	5	0,014672	0,107106	16,18420	0,93631	0,97271	0,86644	0,93478
	10	0,015168	0,105092	16,32005	0,93913	0,97422	0,82208	0,92711
	15	0,010500	0,083399	14,43952	0,96017	0,96751	0,94589	0,95416
	20	0,008451	0,074826	12,05691	0,93865	0,95410	0,86468	0,93237

EK 5. 2008-2014 yılları arası (4 ay) Yapay Sinir Ağı (Bayesyen Düzeltme Geri Yayılım) uygulaması performans sonuçları.

Hisse Senedi	Nöron Sayısı	MSE	MAE	MAPE	Training	Test	All
AKBANK	5	0,010829	0,089287	16,78538	0,81874	0,82598	0,81433
	10	0,010359	0,086291	16,40059	0,82328	0,75348	0,81870
	15	0,011667	0,093061	17,15814	0,81825	0,74031	0,80832
	20	0,011564	0,092268	16,84823	0,82201	0,68631	0,80719
AKSA	5	0,003781	0,048993	6,566250	0,96140	0,97412	0,96215
	10	0,002331	0,036551	4,879018	0,96496	0,95101	0,96345
	15	0,004714	0,058027	7,362267	0,95820	0,97998	0,96109
	20	0,005795	0,064317	8,143496	0,95728	0,97075	0,95995
ARÇELİK	5	0,003701	0,048230	6,026791	0,97723	0,92661	0,97480
	10	0,003624	0,047229	6,352308	0,96506	0,94673	0,96421
	15	0,004395	0,055390	6,958874	0,96376	0,96252	0,96334
	20	0,005118	0,061431	7,717489	0,95935	0,99169	0,96277
ASYA KATILIM BANKASI	5	0,000956	0,026034	20,41419	0,97480	0,97341	0,97266
	10	0,001236	0,029253	23,19352	0,97814	0,82877	0,96979
	15	0,000868	0,024854	19,49688	0,97479	0,89301	0,96851
	20	0,001124	0,027534	21,82048	0,97840	0,92991	0,97410
BİM MAĞAZALAR	5	0,000580	0,019559	8,943705	0,98581	0,90641	0,97576
	10	0,000605	0,019493	9,041963	0,98763	0,80109	0,95818
	15	0,000570	0,018828	8,717603	0,92949	0,95817	0,93209
	20	0,000639	0,019781	9,123858	0,93370	0,92723	0,93258
DOĞAN HOLDİNG	5	0,000781	0,021943	8,979047	0,93593	0,92636	0,93467
	10	0,001457	0,029735	11,80507	0,90310	0,69426	0,88803
	15	0,001201	0,027439	11,67747	0,91354	0,64836	0,88414
	20	0,024624	0,151562	64,74134	0,74186	0,77485	0,74020
ENKA İNŞAAT	5	0,001089	0,027755	11,79659	0,97664	0,76311	0,97247
	10	0,000552	0,021224	8,576953	0,89880	0,97746	0,94172
	15	0,000659	0,023425	9,363342	0,92646	0,98709	0,94385
	20	0,000931	0,024735	9,474995	0,95449	0,70630	0,94451
EREĞLİ DEMİR ÇELİK	5	0,001938	0,034467	12,79511	0,97243	0,92059	0,96437
	10	0,001614	0,031907	12,05460	0,97868	0,73812	0,96175
	15	0,002078	0,035727	13,29625	0,97080	0,91398	0,96671
	20	0,001953	0,033461	12,46385	0,97051	0,92455	0,96377
GARANTİ BANKASI	5	0,007133	0,067816	9,709487	0,92562	0,94774	0,92946
	10	0,006469	0,066168	9,486399	0,92391	0,94622	0,92879
	15	0,006850	0,068941	9,959362	0,93164	0,94117	0,92745
	20	0,007099	0,069510	10,02116	0,92686	0,88925	0,92861
İHLAS HOLDİNG	5	0,000240	0,012985	8,377167	0,96515	0,78228	0,91815
	10	0,000346	0,015725	10,34374	0,96546	0,93722	0,96241
	15	0,000631	0,022189	14,64968	0,96541	0,84108	0,94292
	20	0,002630	0,049065	33,10355	0,88313	0,95802	0,88784
İŞ BANKASI	5	0,017533	0,114541	22,81550	0,76536	0,72743	0,75911
	10	0,018520	0,110994	19,53020	0,57923	0,63018	0,58136
	15	0,025614	0,142194	25,84371	0,63119	0,53056	0,61234
	20	0,017299	0,116575	22,19973	0,69187	0,89742	0,72361
KARDEMİR	5	0,061434	0,172802	25,66660	0,97055	0,92439	0,95196
	10	0,012984	0,092405	13,89757	0,92788	0,93539	0,92998
	15	0,014702	0,096156	14,54642	0,96728	0,84695	0,94288
	20	0,027526	0,135807	19,40782	0,93303	0,80287	0,91531
KOÇ HOLDİNG	5	0,008135	0,075114	9,754317	0,96142	0,94139	0,95746
	10	0,010775	0,080551	10,88851	0,93553	0,94657	0,9346
	15	0,017385	0,102771	13,90665	0,91984	0,87441	0,91552
	20	0,053265	0,211669	27,82052	0,92004	0,92969	0,92179

EK 5. 2008-2014 yılları arası (4 ay) Yapay Sinir Ağı (Bayesyen Düzeltme Geri Yayılım) uygulaması performans sonuçları (devamı).

Hisse Senedi	Nöron Sayısı	MSE	MAE	MAPE	Training	Test	All
PETKİM	5	0,000295	0,014012	6,988205	0,99514	0,96740	0,99276
	10	0,000322	0,013045	6,244199	0,99862	0,75645	0,92680
	15	0,000358	0,014181	6,570250	0,99864	0,65289	0,95496
	20	0,000431	0,016403	7,760928	0,99822	0,86713	0,98743
SABANCI	5	0,002904	0,038467	5,914479	0,94352	0,97416	0,94838
	10	0,002550	0,037232	5,722982	0,95081	0,91727	0,94590
	15	0,002829	0,038341	5,867039	0,94267	0,96361	0,94676
	20	0,002966	0,038902	5,964944	0,94644	0,95109	0,94621
SİNPAŞ	5	0,001358	0,031890	27,63522	0,98769	0,73492	0,92475
	10	0,000690	0,021510	19,07829	0,98316	0,85753	0,94847
	15	0,000996	0,028448	24,68952	0,98360	0,81470	0,93297
	20	0,002349	0,047653	40,09788	0,93576	0,75488	0,89402
ŞİŞE CAM	5	0,004300	0,059102	10,56414	0,94740	0,94104	0,94298
	10	0,003534	0,052284	9,368369	0,93481	0,98386	0,94439
	15	0,003375	0,049832	9,107724	0,94461	0,94915	0,94446
	20	0,002852	0,041608	7,726240	0,92320	0,98143	0,92887
T. HALK BANKASI	5	0,008049	0,081167	13,06941	0,96102	0,92410	0,95205
	10	0,003886	0,057389	9,648300	0,92782	0,93543	0,93641
	15	0,003667	0,052345	8,915974	0,94040	0,91753	0,93519
	20	0,003466	0,049912	8,305403	0,91228	0,96525	0,91863
TEKFEN	5	0,001405	0,034629	8,567715	0,89345	0,95443	0,90006
	10	0,001809	0,040443	9,722704	0,86625	0,68718	0,85476
	15	0,001946	0,041886	10,14664	0,87400	0,68299	0,85975
	20	0,002895	0,042500	10,38104	0,82297	0,98867	0,85763
TOFAŞ	5	0,005715	0,061345	8,210059	0,97275	0,95936	0,96970
	10	0,007907	0,076413	9,911450	0,96363	0,97535	0,96558
	15	0,007438	0,072596	9,451844	0,97531	0,93054	0,96518
	20	0,011514	0,096403	12,58010	0,95257	0,93870	0,95077
TURKCELL	5	0,010222	0,091892	12,43773	0,81326	0,76942	0,79482
	10	0,008994	0,079051	10,19344	0,77395	0,53367	0,78234
	15	0,008254	0,075809	9,858850	0,79095	0,50380	0,78427
	20	0,006087	0,058846	7,427910	0,72050	0,93028	0,75027
TÜPRAŞ	5	0,008708	0,079599	10,51840	0,94456	0,97073	0,94399
	10	0,009898	0,088530	11,61025	0,93202	0,96311	0,93535
	15	0,008883	0,083564	11,05669	0,93522	0,96683	0,93414
	20	0,007685	0,074682	9,878254	0,91861	0,95679	0,92357
TÜRK HAVA YOLLARI	5	0,015688	0,088281	12,61003	0,92262	0,92768	0,91815
	10	0,007076	0,062130	9,055520	0,81961	0,93151	0,83016
	15	0,006751	0,061462	9,096538	0,82221	0,89811	0,82675
	20	0,005798	0,061937	9,518815	0,80444	0,93544	0,82840
TÜRK TRAKTÖR	5	0,050651	0,187973	23,26006	0,99406	0,99453	0,99417
	10	0,005456	0,061423	7,857813	0,98359	0,98629	0,98326
	15	0,011800	0,097083	12,13754	0,98709	0,98431	0,98471
	20	0,007701	0,078268	10,19312	0,99481	0,93385	0,98217
VAKIFLAR BANKASI	5	0,004572	0,055896	9,456583	0,91985	0,97001	0,92528
	10	0,005013	0,054325	9,137721	0,90363	0,90124	0,90355
	15	0,012789	0,089802	16,19181	0,90005	0,69173	0,88880
	20	0,015254	0,096961	16,75409	0,87316	0,82356	0,86381
YAPI VE KREDİ BANK	5	0,007419	0,069972	11,52057	0,91710	0,91767	0,91981
	10	0,007114	0,071895	12,19007	0,89650	0,92691	0,89780
	15	0,014444	0,085746	15,62018	0,86154	0,92671	0,87088
	20	0,017955	0,103486	17,98995	0,89296	0,84973	0,88595

EK 6. Üstel Düzeltme Yöntemi α katsayısına göre MAPE sonuçları.

Hisse Senedi	0,1	0,2	0,3	0,4	0,5	0,6	0,7	0,8	0,9
AKBANK	12,13	11,65	11,09	10,46	9,760	9,060	8,680	8,620	8,530
AKSA	7,930	4,060	4,630	4,960	5,050	5,160	5,330	5,460	5,620
ARÇELİK	8,310	6,370	5,960	5,760	5,610	5,640	5,690	5,660	5,550
ASYA KATILIM BANKASI	58,99	40,47	32,97	28,38	25,05	22,18	19,53	17,31	15,86
BİM MAĞAZALAR	14,74	6,990	6,280	5,580	5,280	5,280	5,390	5,480	5,540
DOĞAN HOLDİNG	14,03	11,08	9,720	8,820	8,220	7,540	6,940	6,340	5,970
ENKA İNŞAAT	7,550	7,460	6,560	5,640	5,190	4,970	4,830	4,730	4,660
EREĞLİ DEMİR ÇELİK	21,26	17,14	13,41	10,99	9,370	8,350	7,770	7,810	7,890
GARANTİ BANKASI	12,32	11,67	11,14	10,32	9,470	8,860	8,210	7,900	7,690
İHLAS HOLDİNG	98,76	49,65	29,20	21,24	16,62	13,66	12,29	11,35	10,50
İŞ BANKASI	13,30	12,41	11,65	11,23	10,85	10,34	9,750	9,190	8,870
KARDEMİR	24,69	19,41	16,23	15,08	14,44	13,82	13,18	12,51	11,91
KOÇ HOLDİNG	13,83	11,28	9,860	8,940	8,200	7,490	7,030	6,700	6,470
PETKİM	13,64	11,75	10,29	8,960	7,800	7,030	6,470	5,980	5,590
SABANCI	9,700	8,900	7,870	7,050	6,610	6,130	5,670	5,470	5,600
SİNPAŞ	29,78	13,92	10,86	9,880	8,840	8,240	7,880	7,400	6,850
ŞİŞE CAM	12,50	11,61	10,57	9,690	9,180	8,610	8,010	7,410	7,030
T. HALK BANKASI	12,00	11,87	11,54	11,13	10,52	9,990	9,460	8,890	8,520
TEKFEN	9,330	7,280	6,100	5,850	5,750	5,710	5,870	6,010	6,090
TOFAŞ	11,60	9,070	8,760	8,530	8,230	7,870	7,450	6,990	6,500
TURKCELL	8,620	6,380	6,110	6,040	5,980	5,880	5,710	5,480	5,210
TÜPRAŞ	10,04	9,360	8,770	8,260	7,720	7,360	7,100	7,110	7,180
TÜRK HAVA YOLLARI	8,160	8,300	8,150	7,610	7,180	6,760	6,370	6,200	6,140
TÜRK TRAKTÖR	12,54	9,380	8,240	7,460	7,150	6,690	6,390	6,280	6,250
VAKIFLAR BANKASI	12,84	12,42	11,87	11,26	10,59	9,990	9,500	9,000	8,580
YAPI VE KREDİ BANK	12,79	12,08	11,47	10,76	10,02	9,280	8,860	8,570	8,620
ORTALAMA	18,13	13,122	11,13	9,995	9,180	8,5342	8,052	7,686	7,432

Ek 7. MAPE deęerleri kullanılarak Model 2 için yöntemlerin seçilmesi.

Hisse Senedi	Levenberg-Marquardt Geri Yayılım Algoritması				Bayesyen Düzeltme Geri Yayılım Algoritması			
	YSA (5 Nöron)	YSA (10 Nöron)	YSA (15 Nöron)	YSA (20 Nöron)	YSA (5 Nöron)	YSA (10 Nöron)	YSA (15 Nöron)	YSA (20 Nöron)
AKBANK	8,847513	11,39152	14,42517	7,203090	9,036460	8,789879	9,335251	9,209413
AKSA	5,843253	14,37778	15,19102	5,150442	6,227419	4,624856	6,997109	7,740498
ARÇELİK	5,800560	11,08345	6,234957	6,691346	6,053794	6,385278	6,992640	7,754904
ASYA KATILIM BANKASI	35,84825	29,38616	23,46221	28,50418	27,85462	31,66902	26,58931	29,85046
BİM MAĞAZALAR	4,953380	6,399545	5,421634	5,545035	5,369306	5,396050	5,20426	5,458232
DOĞAN HOLDİNG	7,099690	7,090432	5,694588	9,073680	4,56555	6,059983	5,796006	32,17682
ENKA İNŞAAT	4,220913	7,168124	5,732877	5,138963	6,486092	4,818724	5,282343	5,445195
EREĞLİ DEMİR ÇELİK	8,573997	9,743512	7,075859	11,00782	9,408414	8,809627	9,762295	9,157825
GARANTİ BANKASI	10,75948	9,615128	11,81734	9,587316	8,332665	8,140453	8,538614	8,594372
İHLAS HOLDİNG	24,71287	23,29692	13,58583	20,06467	9,575315	11,85588	16,79485	38,06221
İŞ BANKASI	10,98455	10,27226	11,19281	12,01139	9,843359	9,139148	11,84737	9,936179
KARDEMİR	23,92183	36,18194	18,48095	14,0848	22,70107	12,46598	12,81195	17,22880
KOÇ HOLDİNG	11,50953	7,561719	9,380462	8,415983	8,995175	10,00598	12,77725	25,63919
PETKİM	6,221903	8,954644	6,665179	9,329464	5,661056	5,100542	5,398420	6,353975
SABANCI	6,135363	12,13379	9,737319	6,453793	5,066017	4,902665	5,029981	5,112552
SİNPAŞ	25,57430	7,346823	8,894847	38,69438	24,37789	16,78262	21,77293	35,48965
ŞİŞE CAM	8,483610	8,740232	13,23544	7,584632	8,529411	7,562534	7,326366	6,201518

Ek 7. MAPE deęerleri kullanılarak Model 2 için yöntemlerin seçilmesi (devamı).

Hisse Senedi	Levenberg-Marquardt Geri Yayılım Algoritması				Bayesyen Düzeltme Geri Yayılım Algoritması			
	YSA (5 Nöron)	YSA (10 Nöron)	YSA (15 Nöron)	YSA (20 Nöron)	YSA (5 Nöron)	YSA (10 Nöron)	YSA (15 Nöron)	YSA (20 Nöron)
T. HALK BANKASI	10,60490	16,15284	14,78593	8,388958	11,66876	8,567560	7,907318	7,389673
TEKFEN	5,999778	5,802451	7,227501	5,580188	5,629287	6,451937	6,715679	6,855670
TOFAŞ	9,307597	8,829374	7,190228	13,60231	8,673806	10,44951	9,967510	13,26589
TURKCELL	5,007565	8,885351	5,811845	24,85862	6,494149	5,451469	5,250111	4,019030
TÜPRAŞ	9,915054	7,939929	7,308571	9,220219	8,303742	9,185185	8,728470	7,795906
TÜRK HAVA YOLLARI	8,091139	9,879191	7,832599	9,197826	10,62866	7,610360	7,626942	7,940846
TÜRK TRAKTÖR	11,18621	11,52909	10,68011	15,24799	24,81341	8,523828	13,13554	11,07205
VAKIFLAR BANKASI	11,03601	13,88624	14,15336	12,50742	8,535487	8,255198	14,50082	15,09255
YAPI VE KREDİ BANK	8,642323	10,00991	11,47642	10,22474	8,274629	8,683413	10,85799	12,73054
Seçilme Sayısı	3	2	4	2	3	9	0	3

Ek 8. MAPE deęerleri kullanılarak Model 3 için yöntemlerin seçilmesi.

Hisse Senedi	Levenberg-Marquardt Geri Yayılım Algoritması				Bayesyen Düzeltme Geri Yayılım Algoritması				Üstel Düzeltme Yöntemi
	YSA (5 Nöron)	YSA (10 Nöron)	YSA (15 Nöron)	YSA (20 Nöron)	YSA (5 Nöron)	YSA (10 Nöron)	YSA (15 Nöron)	YSA (20 Nöron)	
AKBANK	8,847513	11,39152	14,42517	7,20309	9,03646	8,789879	9,335251	9,209413	8,53
AKSA	5,843253	14,37778	15,19102	5,150442	6,227419	4,624856	6,997109	7,740498	5,62
ARÇELİK	5,80056	11,08345	6,234957	6,691346	6,053794	6,385278	6,99264	7,754904	5,55
ASYA KATILIM BANKASI	35,84825	29,38616	23,46221	28,50418	27,85462	31,66902	26,58931	29,85046	15,86
BİM MAĞAZALAR	4,95338	6,399545	5,421634	5,545035	5,369306	5,39605	5,20426	5,458232	5,54
DOĞAN HOLDİNG	7,09969	7,090432	5,694588	9,07368	4,56555	6,059983	5,796006	32,17682	5,97
ENKA İNŞAAT	4,220913	7,168124	5,732877	5,138963	6,486092	4,818724	5,282343	5,445195	4,66
EREĞLİ DEMİR ÇELİK	8,573997	9,743512	7,075859	11,00782	9,408414	8,809627	9,762295	9,157825	7,89
GARANTİ BANKASI	10,75948	9,615128	11,81734	9,587316	8,332665	8,140453	8,538614	8,594372	7,69
İHLAS HOLDİNG	24,71287	23,29692	13,58583	20,06467	9,575315	11,85588	16,79485	38,06221	10,50
İŞ BANKASI	10,98455	10,27226	11,19281	12,01139	9,843359	9,139148	11,84737	9,936179	8,87
KARDEMİR	23,92183	36,18194	18,48095	14,0848	22,70107	12,46598	12,81195	17,2288	11,91
KOÇ HOLDİNG	11,50953	7,561719	9,380462	8,415983	8,995175	10,00598	12,77725	25,63919	6,47
PETKİM	6,221903	8,954644	6,665179	9,329464	5,661056	5,100542	5,39842	6,353975	5,59
SABANCI	6,135363	12,13379	9,737319	6,453793	5,066017	4,902665	5,029981	5,112552	5,60
SİNPAŞ	25,5743	7,346823	8,894847	38,69438	24,37789	16,78262	21,77293	35,48965	6,85
ŞİŞE CAM	8,48361	8,740232	13,23544	7,584632	8,529411	7,562534	7,326366	6,201518	7,03

Ek 8. MAPE deęerleri kullanılarak Model 3 için yöntemlerin seęilmesi (devamı).

Hisse Senedi	Levenberg-Marquardt Geri Yayılım Algoritması				Bayesyen Düzeltme Geri Yayılım Algoritması				Üstel Düzeltme Yöntemi
	YSA (5 Nöron)	YSA (10 Nöron)	YSA (15 Nöron)	YSA (20 Nöron)	YSA (5 Nöron)	YSA (10 Nöron)	YSA (15 Nöron)	YSA (20 Nöron)	
T. HALK BANKASI	10,6049	16,15284	14,78593	8,388958	11,66876	8,56756	7,907318	7,389673	8,52
TEKFEN	5,999778	5,802451	7,227501	5,580188	5,629287	6,451937	6,715679	6,85567	6,09
TOFAŞ	9,307597	8,829374	7,190228	13,60231	8,673806	10,44951	9,96751	13,26589	6,50
TURKCELL	5,007565	8,885351	5,811845	24,85862	6,494149	5,451469	5,250111	4,01903	5,21
TÜPRAŞ	9,915054	7,939929	7,308571	9,220219	8,303742	9,185185	8,72847	7,795906	7,18
TÜRK HAVA YOLLARI	8,091139	9,879191	7,832599	9,197826	10,62866	7,61036	7,626942	7,940846	6,14
TÜRK TRAKTÖR	11,18621	11,52909	10,68011	15,24799	24,81341	8,523828	13,13554	11,07205	6,25
VAKIFLAR BANKASI	11,03601	13,88624	14,15336	12,50742	8,535487	8,255198	14,50082	15,09255	8,58
YAPI VE KREDİ BANK	8,642323	10,00991	11,47642	10,22474	8,274629	8,683413	10,85799	12,73054	8,62
Seęilme Sayısı	2	0	1	2	3	4	0	3	11

Ek 9. Portföy Optimizasyonunda modeller için hesaplanan beklenen getiriler.

Hisse Senedi/Model	Gerçek Veriler(2014)	Üstel Düzeltme	YSA LM-BR	YSA LM-BR-Üstel	Geçmiş Gerçek Veriler (2008-2013)
AKBANK	0,041310000	0,029200000	0,026130000	0,026130000	0,007650000
AKSA	0,001989000	-0,00508000	-0,00398000	-0,00398000	0,028985000
ARÇELİK	0,028774889	0,014361800	0,003547604	0,014361800	0,019489903
ASYA KATILIM BANKASI	-0,03359357	-0,05394354	-0,00874072	-0,05394354	-0,01060890
BİM MAĞAZALAR	0,025740003	0,013887230	0,010458892	0,010458892	0,003683254
DOĞAN HOLDİNG	0,010926811	0,002946485	0,017698129	0,017698129	-0,00245283
ENKA İNŞAAT	-0,016728566	-0,00442765	-0,00099560	-0,00099560	-0,00408723
EREĞLİ DEMİR ÇELİK	0,051070281	0,055651545	0,055364814	0,055364814	-0,00527060
GARANTİ BANKASI	0,045477875	0,032952348	0,023047892	0,032952348	0,009032802
İHLAS HOLDİNG	-0,007140001	-0,02406913	-0,01205098	-0,01205098	0,008043415
İŞ BANKASI	0,051216540	0,028095290	0,033218620	0,028095290	0,004332970
KARDEMİR	0,077227500	0,070506100	0,067907300	0,070506100	0,010625400
KOÇ HOLDİNG	0,046079477	0,032901712	0,041290076	0,032901712	0,017185946
PETKİM	0,042810000	0,031570000	0,046270000	0,046270000	0,004290000
SABANCI	0,029699000	0,019807000	0,016479000	0,016479000	0,015626000
SİNPAŞ	0,016700000	0,002200000	0,004200000	0,002200000	-0,01320000
ŞİŞE CAM	0,037500000	0,026314000	0,023681000	0,026314000	0,014049000
T. HALK BANKASI	0,025382688	0,025115093	0,036951591	0,036951591	0,013997246
TEKFEN	0,021100000	0,018400000	0,013300000	0,013300000	0,003500000
TOFAŞ	0,039300000	0,017600000	0,015100000	0,017600000	0,024378700
TURKCELL	0,024482000	0,019411000	0,017118000	0,017118000	0,005111000
TÜPRAŞ	0,038830000	0,015930000	0,021990000	0,015930000	0,010550400
TÜRK HAVA YOLLARI	0,036789857	0,032634848	0,017838305	0,032634848	0,016380528
TÜRK TRAKTÖR	0,037564778	0,013325765	0,007097288	0,013325765	0,032832122
VAKIFLAR BANKASI	0,037098961	0,028747561	0,036815945	0,036815945	0,014394245
YAPI VE KREDİ BANK	0,043640126	0,034850072	0,025192530	0,02519253	0,009598481

EK 10. Portföy Optimizasyonu Analizinde Model 0 için hesaplanan varyans-kovaryans matrisi.

	1	2	3	4	5	6	7	8	9	10	11	12	13
1	0,0073	-0,0013	0,0022	0,0056	0,0023	0,0041	0,0007	0,0029	0,0066	0,0047	0,0062	0,0028	0,0041
2	-0,0013	0,0050	0,0021	-0,0011	-0,0011	0,0014	0,0018	-0,0004	-0,0016	-0,0005	-0,0009	0,0029	0,0002
3	0,0022	0,0021	0,0030	0,0013	0,0009	0,0022	0,0010	0,0003	0,0017	0,0022	0,0025	0,0030	0,0016
4	0,0056	-0,0011	0,0013	0,0211	0,0043	0,0047	0,0008	-0,0023	0,0050	-0,0045	0,0044	0,0045	0,0030
5	0,0023	-0,0011	0,0009	0,0043	0,0041	-0,0012	0,0004	0,0025	0,0024	0,0030	0,0013	0,0042	0,0013
6	0,0041	0,0014	0,0022	0,0047	-0,0012	0,0069	0,0001	-0,0002	0,0032	-0,0005	0,0056	0,0008	0,0028
7	0,0007	0,0018	0,0010	0,0008	0,0004	0,0001	0,0023	-0,0009	0,0007	0,0012	-0,0006	0,0003	0,0008
8	0,0029	-0,0004	0,0003	-0,0023	0,0025	-0,0002	-0,0009	0,0100	0,0024	0,0050	0,0017	0,0061	0,0012
9	0,0066	-0,0016	0,0017	0,0050	0,0024	0,0032	0,0007	0,0024	0,0063	0,0044	0,0057	0,0021	0,0037
10	0,0047	-0,0005	0,0022	-0,0045	0,0030	-0,0005	0,0012	0,0050	0,0044	0,0134	0,0031	0,0029	0,0033
11	0,0062	-0,0009	0,0025	0,0044	0,0013	0,0056	-0,0006	0,0017	0,0057	0,0031	0,0080	0,0017	0,0037
12	0,0028	0,0029	0,0030	0,0045	0,0042	0,0008	0,0003	0,0061	0,0021	0,0029	0,0017	0,0140	0,0024
13	0,0041	0,0002	0,0016	0,0030	0,0013	0,0028	0,0008	0,0012	0,0037	0,0033	0,0037	0,0024	0,0027
14	0,0030	0,0007	0,0018	0,0015	0,0001	0,0024	0,0005	0,0016	0,0021	0,0020	0,0021	0,0013	0,0014
15	0,0035	0,0002	0,0012	0,0038	0,0001	0,0034	0,0002	0,0001	0,0031	-0,0001	0,0035	0,0024	0,0022
16	0,0030	0,0001	0,0015	0,0032	0,0010	0,0014	-0,0002	0,0017	0,0025	0,0001	0,0021	0,0042	0,0014
17	0,0033	0,0014	0,0024	-0,0009	-0,0001	0,0032	0,0001	0,0038	0,0026	0,0008	0,0037	0,0026	0,0015
18	0,0081	-0,0021	0,0016	0,0082	0,0029	0,0046	0,0004	0,0037	0,0075	0,0026	0,0069	0,0046	0,0045
19	0,0034	-0,0004	0,0015	0,0043	0,0003	0,0027	0,0010	-0,0014	0,0028	-0,0010	0,0024	0,0001	0,0017
20	0,0038	-0,0007	0,0013	0,0039	0,0018	0,0016	0,0012	0,0010	0,0037	0,0021	0,0030	0,0001	0,0020
21	0,0033	0,0014	0,0022	0,0010	0,0007	0,0030	0,0009	0,0017	0,0031	0,0035	0,0038	0,0022	0,0024
22	0,0044	-0,0011	0,0021	0,0052	0,0026	0,0028	-0,0005	0,0012	0,0040	0,0032	0,0052	0,0025	0,0025
23	0,0036	0,0004	0,0019	0,0010	-0,0013	0,0044	0,0020	-0,0030	0,0031	0,0012	0,0037	-0,0048	0,0022
24	-0,0002	0,0021	0,0013	0,0013	0,0002	0,0015	-0,0004	0,0013	-0,0007	0,0007	0,0006	0,0031	0,0003
25	0,0080	-0,0017	0,0023	0,0082	0,0032	0,0050	0,0002	0,0037	0,0073	0,0023	0,0074	0,0045	0,0043
26	0,0072	-0,0018	0,0018	0,0069	0,0028	0,0033	0,0008	0,0021	0,0068	0,0038	0,0057	0,0036	0,0040

EK 10. Portföy Optimizasyonu Analizinde Model 0 için hesaplanan varyans-kovaryans matrisi (devamı).

	14	15	16	17	18	19	20	21	22	23	24	25	26
1	0,0030	0,0035	0,0030	0,0033	0,0081	0,0034	0,0038	0,0033	0,0044	0,0036	-0,0002	0,0080	0,0072
2	0,0007	0,0002	0,0001	0,0014	-0,0021	-0,0004	-0,0007	0,0014	-0,0011	0,0004	0,0021	-0,0017	-0,0018
3	0,0018	0,0012	0,0015	0,0024	0,0016	0,0015	0,0013	0,0022	0,0021	0,0019	0,0013	0,0023	0,0018
4	0,0015	0,0038	0,0032	-0,0009	0,0082	0,0043	0,0039	0,0010	0,0052	0,0010	0,0013	0,0082	0,0069
5	0,0001	0,0001	0,0010	-0,0001	0,0029	0,0003	0,0018	0,0007	0,0026	-0,0013	0,0002	0,0032	0,0028
6	0,0024	0,0034	0,0014	0,0032	0,0046	0,0027	0,0016	0,0030	0,0028	0,0044	0,0015	0,0050	0,0033
7	0,0005	0,0002	-0,0002	0,0001	0,0004	0,0010	0,0012	0,0009	-0,0005	0,0020	-0,0004	0,0002	0,0008
8	0,0016	0,0001	0,0017	0,0038	0,0037	-0,0014	0,0010	0,0017	0,0012	-0,0030	0,0013	0,0037	0,0021
9	0,0021	0,0031	0,0025	0,0026	0,0075	0,0028	0,0037	0,0031	0,0040	0,0031	-0,0007	0,0073	0,0068
10	0,0020	-0,0001	0,0001	0,0008	0,0026	-0,0010	0,0021	0,0035	0,0032	0,0012	0,0007	0,0023	0,0038
11	0,0021	0,0035	0,0021	0,0037	0,0069	0,0024	0,0030	0,0038	0,0052	0,0037	0,0006	0,0074	0,0057
12	0,0013	0,0024	0,0042	0,0026	0,0046	0,0001	0,0001	0,0022	0,0025	-0,0048	0,0031	0,0045	0,0036
13	0,0014	0,0022	0,0014	0,0015	0,0045	0,0017	0,0020	0,0024	0,0025	0,0022	0,0003	0,0043	0,0040
14	0,0032	0,0012	0,0022	0,0028	0,0024	0,0019	0,0014	0,0015	0,0015	0,0020	0,0010	0,0028	0,0023
15	0,0012	0,0030	0,0022	0,0019	0,0046	0,0023	0,0012	0,0017	0,0018	0,0017	0,0000	0,0043	0,0038
16	0,0022	0,0022	0,0039	0,0027	0,0038	0,0021	0,0010	0,0009	0,0017	-0,0005	0,0005	0,0038	0,0035
17	0,0028	0,0019	0,0027	0,0057	0,0036	0,0021	0,0017	0,0025	0,0016	0,0023	0,0006	0,0045	0,0025
18	0,0024	0,0046	0,0038	0,0036	0,0106	0,0042	0,0041	0,0032	0,0045	0,0028	-0,0008	0,0101	0,0087
19	0,0019	0,0023	0,0021	0,0021	0,0042	0,0043	0,0023	0,0009	0,0015	0,0042	-0,0012	0,0045	0,0036
20	0,0014	0,0012	0,0010	0,0017	0,0041	0,0023	0,0031	0,0018	0,0023	0,0031	-0,0008	0,0044	0,0038
21	0,0015	0,0017	0,0009	0,0025	0,0032	0,0009	0,0018	0,0030	0,0023	0,0023	0,0009	0,0034	0,0029
22	0,0015	0,0018	0,0017	0,0016	0,0045	0,0015	0,0023	0,0023	0,0046	0,0015	0,0010	0,0052	0,0042
23	0,0020	0,0017	-0,0005	0,0023	0,0028	0,0042	0,0031	0,0023	0,0015	0,0084	-0,0015	0,0035	0,0027
24	0,0010	0,0000	0,0005	0,0006	-0,0008	-0,0012	-0,0008	0,0009	0,0010	-0,0015	0,0029	-0,0004	-0,0009
25	0,0028	0,0043	0,0038	0,0045	0,0101	0,0045	0,0044	0,0034	0,0052	0,0035	-0,0004	0,0105	0,0082
26	0,0023	0,0038	0,0035	0,0025	0,0087	0,0036	0,0038	0,0029	0,0042	0,0027	-0,0009	0,0082	0,0079

1= AKBANK, 2= AKSA, 3=ARÇELİK, 4=ASYA KAT.BANK., 5=BİM MAĞAZALAR, 6=DOĞAN HOLDİNG, 7=ENKA İNŞAAT, 8=EREĞLİ DEM-ÇEL, 9=GARANTİ BANKASI, 10=İHLAS HOLD., 11=İŞ BANKASI, 12=KARDEMİR, 13=KOÇ HOLD., 14=PETKİM, 15=SABANCI, 16=SİNPAŞ, 17=ŞİŞE CAM, 18=T. HALK BANKASI, 19=TEKFEN, 20=TOFAŞ, 21=TRKCELL, 22=TÜPRAŞ, 23=THY, 24=TÜRK TRAKTÖR, 25=VAKIFLAR BANKASI, 26=YAPI VE KREDİ BANK

EK 11. Portföy Optimizasyonu Analizinde Model 1 için hesaplanan varyans-kovaryans matrisi.

	1	2	3	4	5	6	7	8	9	10	11	12	13
1	0,0083	0,0000	0,00363	0,0081	0,00374	0,0044	-0,0008	0,00225	0,0078	0,0061	0,0080	0,00447	0,00559
2	0,0000	0,0040	0,00211	-0,0001	-0,00031	0,0016	0,0009	0,00009	-0,0001	0,0003	0,0004	0,00291	0,00105
3	0,0036	0,0021	0,00313	0,0032	0,00185	0,0023	0,0004	0,00063	0,0033	0,0032	0,0035	0,00397	0,00293
4	0,0081	-0,0001	0,00323	0,0216	0,00594	0,0053	-0,0010	-0,00115	0,0077	-0,0001	0,0076	0,00723	0,00556
5	0,0037	-0,0003	0,00185	0,0059	0,00456	-0,0003	-0,0005	0,00204	0,0038	0,0044	0,0029	0,00513	0,00277
6	0,0044	0,0016	0,00230	0,0053	-0,00031	0,0060	-0,0001	0,00030	0,0037	0,0003	0,0054	0,00192	0,00310
7	-0,0008	0,0009	0,00042	-0,0010	-0,00045	-0,0001	0,0019	-0,00130	-0,0007	0,0001	-0,001	-0,00163	-0,0005
8	0,0023	0,0001	0,00063	-0,0012	0,00204	0,0003	-0,0013	0,00788	0,0019	0,0042	0,0020	0,00510	0,00115
9	0,0078	-0,0001	0,00331	0,0077	0,00384	0,0037	-0,0007	0,00186	0,0076	0,0059	0,0077	0,00394	0,00538
10	0,0062	0,0004	0,00320	-0,0002	0,00443	0,0003	0,0001	0,00426	0,0059	0,0133	0,0049	0,00449	0,00491
11	0,0080	0,0004	0,00352	0,0076	0,00289	0,0054	-0,0010	0,00199	0,0077	0,0049	0,0088	0,00441	0,00564
12	0,0045	0,0029	0,00397	0,0072	0,00513	0,0019	-0,0016	0,00510	0,0039	0,0044	0,0044	0,01296	0,00396
13	0,0056	0,0010	0,00293	0,0056	0,00277	0,0031	-0,0005	0,00115	0,0054	0,0049	0,0056	0,00396	0,00438
14	0,0043	0,0012	0,00254	0,0036	0,00134	0,0026	-0,0004	0,00153	0,0036	0,0031	0,0036	0,00284	0,00286
15	0,0049	0,0010	0,00258	0,0060	0,00176	0,0037	-0,0011	0,00018	0,0047	0,0019	0,0055	0,00372	0,00379
16	0,0053	0,0007	0,00308	0,0061	0,00304	0,0022	-0,0017	0,00183	0,0049	0,0026	0,0050	0,00608	0,00369
17	0,0045	0,0018	0,00299	0,0017	0,00099	0,0034	-0,0006	0,00321	0,0040	0,0021	0,0048	0,00369	0,00300
18	0,0078	-0,0007	0,00293	0,0093	0,00365	0,0047	-0,0012	0,00242	0,0073	0,0038	0,0081	0,00465	0,00499
19	0,0036	0,0001	0,00200	0,0045	0,00099	0,0026	0,0001	-0,00136	0,0032	0,0005	0,0034	0,00051	0,00222
20	0,0065	0,0007	0,00320	0,0071	0,00377	0,0024	-0,0003	0,00106	0,0065	0,0050	0,0059	0,00320	0,00480
21	0,0034	0,0014	0,00224	0,0020	0,00110	0,0028	0,0005	0,00147	0,0032	0,0033	0,0039	0,00237	0,00264
22	0,0064	0,0000	0,00289	0,0078	0,00378	0,0030	-0,0008	0,00162	0,0061	0,0048	0,0062	0,00498	0,00447
23	0,0031	0,0005	0,00171	0,0006	-0,00099	0,0034	0,0018	-0,00250	0,0027	0,0016	0,0032	-0,00406	0,00196
24	0,0031	0,0024	0,00229	0,0046	0,00202	0,0021	-0,0011	0,00215	0,0027	0,0029	0,0029	0,00588	0,00297
25	0,0084	-0,0004	0,00349	0,0098	0,00399	0,0051	-0,0010	0,00276	0,0078	0,0040	0,0085	0,00530	0,00532
26	0,0082	-0,0004	0,00353	0,0093	0,00426	0,0039	-0,0010	0,00133	0,0079	0,0054	0,0080	0,00476	0,00556

EK 11. Portföy Optimizasyonu Analizinde Model 1 için hesaplanan Varyans-Kovaryans Matrisi (devamı).

	14	15	16	17	18	19	20	21	22	23	24	25	26
1	0,0043	0,0049	0,0053	0,0045	0,0078	0,0036	0,0065	0,0034	0,0064	0,0031	0,0031	0,0084	0,0082
2	0,0012	0,0010	0,0007	0,0018	-0,0007	0,0001	0,0007	0,0014	0,0000	0,0005	0,0024	-0,0004	-0,0004
3	0,0025	0,0026	0,0031	0,0030	0,0029	0,0020	0,0032	0,0022	0,0029	0,0017	0,0023	0,0035	0,0035
4	0,0036	0,0060	0,0061	0,0017	0,0093	0,0045	0,0071	0,0020	0,0078	0,0006	0,0046	0,0098	0,0093
5	0,0013	0,0018	0,0030	0,0010	0,0036	0,0010	0,0038	0,0011	0,0038	-0,001	0,0020	0,0040	0,0043
6	0,0026	0,0037	0,0022	0,0034	0,0047	0,0026	0,0024	0,0028	0,0030	0,0034	0,0021	0,0051	0,0039
7	-0,0004	-0,0011	-0,0017	-0,0006	-0,0012	0,0001	-0,0003	0,0005	-0,0008	0,0018	-0,0011	-0,0010	-0,0010
8	0,0015	0,0002	0,0018	0,0032	0,0024	-0,0014	0,0011	0,0015	0,0016	-0,003	0,0021	0,0028	0,0013
9	0,0036	0,0047	0,0049	0,0040	0,0073	0,0032	0,0065	0,0032	0,0061	0,0027	0,0027	0,0078	0,0079
10	0,0032	0,0020	0,0027	0,0021	0,0039	0,0005	0,0050	0,0033	0,0048	0,0016	0,0029	0,0040	0,0055
11	0,0036	0,0055	0,0050	0,0048	0,0081	0,0034	0,0059	0,0039	0,0062	0,0032	0,0029	0,0085	0,0080
12	0,0028	0,0037	0,0061	0,0037	0,0047	0,0005	0,0032	0,0024	0,0050	-0,004	0,0059	0,0053	0,0048
13	0,0029	0,0038	0,0037	0,0030	0,0050	0,0022	0,0048	0,0026	0,0045	0,0020	0,0030	0,0053	0,0056
14	0,0038	0,0026	0,0038	0,0035	0,0033	0,0023	0,0035	0,0017	0,0029	0,0017	0,0027	0,0038	0,0038
15	0,0026	0,0042	0,0041	0,0032	0,0049	0,0026	0,0040	0,0021	0,0040	0,0016	0,0028	0,0052	0,0051
16	0,0038	0,0041	0,0064	0,0043	0,0049	0,0026	0,0045	0,0015	0,0044	-0,000	0,0035	0,0055	0,0057
17	0,0035	0,0032	0,0043	0,0059	0,0042	0,0025	0,0038	0,0025	0,0028	0,0022	0,0023	0,0051	0,0039
18	0,0033	0,0049	0,0049	0,0042	0,0084	0,0035	0,0057	0,0031	0,0062	0,0024	0,0024	0,0090	0,0079
19	0,0023	0,0026	0,0026	0,0025	0,0035	0,0036	0,0033	0,0011	0,0025	0,0035	0,0004	0,0042	0,0037
20	0,0035	0,0040	0,0045	0,0038	0,0057	0,0033	0,0069	0,0024	0,0050	0,0029	0,0028	0,0063	0,0066
21	0,0017	0,0021	0,0015	0,0025	0,0031	0,0011	0,0024	0,0027	0,0025	0,0020	0,0015	0,0034	0,0031
22	0,0029	0,0040	0,0044	0,0028	0,0062	0,0025	0,0050	0,0025	0,0054	0,0012	0,0028	0,0066	0,0066
23	0,0017	0,0016	-0,0004	0,0022	0,0024	0,0035	0,0029	0,0020	0,0012	0,0071	-0,0012	0,0029	0,0025
24	0,0027	0,0028	0,0035	0,0023	0,0024	0,0004	0,0028	0,0015	0,0028	-0,001	0,0045	0,0026	0,0029
25	0,0038	0,0052	0,0055	0,0051	0,0090	0,0042	0,0063	0,0034	0,0066	0,0029	0,0026	0,0097	0,0084
26	0,0038	0,0051	0,0057	0,0039	0,0079	0,0037	0,0066	0,0031	0,0066	0,0025	0,0029	0,0084	0,0085

1= AKBANK, 2= AKSA, 3=ARÇELİK, 4=ASYA KAT.BANK., 5=BİM MAĞAZALAR, 6=DOĞAN HOLDİNG, 7=ENKA İNŞAAT, 8=EREĞLİ DEM-ÇEL, 9=GARANTİ BANKASI, 10=İHLAS HOLD., 11=İŞ BANKASI, 12=KARDEMİR, 13=KOÇ HOLD., 14=PETKİM, 15=SABANCI, 16=SİNPAŞ, 17=ŞİŞE CAM, 18=T. HALK BANKASI, 19=TEKFEN, 20=TOFAŞ, 21=TRKCELL, 22=TÜPRAŞ, 23=THY, 24=TÜRK TRAKTÖR, 25=VAKIFLAR BANKASI, 26=YAPI VE KREDİ BANK

EK 12. Portföy Optimizasyonu Analizinde Model 2 için hesaplanan varyans-kovaryans matrisi.

	1	2	3	4	5	6	7	8	9	10	11	12	13
1	0,0050	-0,0001	0,0005	0,0027	0,0026	0,0006	0,0002	0,0017	0,0048	0,0050	0,0044	-0,0003	0,0045
2	-0,0001	0,0003	0,0000	-0,0003	-0,0001	0,0006	0,0001	0,0002	0,0000	-0,0001	0,0007	0,0010	0,0005
3	0,0005	0,0000	0,0003	0,0007	0,0003	0,0007	0,0002	0,0007	0,0007	0,0005	0,0012	0,0004	-0,0001
4	0,0027	-0,0003	0,0007	0,0290	0,0055	0,0049	0,0006	-0,0024	0,0051	-0,0066	-0,004	0,0086	0,0076
5	0,0026	-0,0001	0,0003	0,0055	0,0031	-0,0002	0,0002	0,0014	0,0026	0,0013	0,0019	0,0035	0,0046
6	0,0006	0,0006	0,0007	0,0049	-0,0002	0,0066	0,0007	-0,0016	0,0027	-0,0003	0,0034	0,0025	0,0015
7	0,0002	0,0001	0,0002	0,0006	0,0002	0,0007	0,0012	-0,0001	-0,0004	0,0007	0,0012	-0,0015	0,0001
8	0,0017	0,0002	0,0007	-0,0024	0,0014	-0,0016	-0,0001	0,0081	-0,0005	0,0014	0,0031	0,0032	-0,0020
9	0,0048	0,0000	0,0007	0,0051	0,0026	0,0027	-0,0004	-0,0005	0,0071	0,0043	0,0051	0,0021	0,0058
10	0,0050	-0,0001	0,0005	-0,0066	0,0013	-0,0003	0,0007	0,0014	0,0043	0,0100	0,0070	-0,0043	0,0035
11	0,0044	0,0007	0,0012	-0,0041	0,0019	0,0034	0,0012	0,0031	0,0051	0,0070	0,0158	0,0030	0,0040
12	-0,0003	0,0010	0,0004	0,0086	0,0035	0,0025	-0,0015	0,0032	0,0021	-0,0043	0,0030	0,0160	0,0062
13	0,0045	0,0005	-0,0001	0,0076	0,0046	0,0015	0,0001	-0,0020	0,0058	0,0035	0,0040	0,0062	0,0126
14	0,0022	0,0005	0,0008	-0,0013	0,0003	0,0028	0,0004	0,0010	0,0036	0,0037	0,0053	0,0007	0,0013
15	0,0021	0,0003	0,0002	0,0057	0,0015	0,0025	-0,0006	-0,0017	0,0045	0,0005	0,0013	0,0034	0,0048
16	0,0002	0,0001	0,0003	-0,0003	0,0006	0,0004	-0,0002	0,0008	0,0010	0,0008	0,0028	0,0028	0,0006
17	0,0026	0,0003	0,0014	0,0011	0,0018	0,0030	-0,0003	0,0028	0,0051	0,0027	0,0073	0,0045	0,0013
18	0,0039	-0,0003	0,0008	0,0095	0,0035	0,0046	0,0007	-0,0016	0,0054	0,0028	0,0039	0,0032	0,0070
19	0,0004	0,0001	0,0006	0,0058	0,0013	0,0021	0,0002	-0,0002	0,0020	-0,0010	-0,000	0,0028	0,0013
20	0,0029	0,0007	0,0008	0,0095	0,0030	0,0025	0,0001	0,0003	0,0056	-0,0001	0,0037	0,0061	0,0058
21	0,0003	0,0005	0,0003	0,0009	0,0008	0,0026	0,0007	-0,0004	0,0011	0,0004	0,0046	0,0031	0,0027
22	0,0006	0,0005	-0,0005	0,0003	0,0005	0,0032	-0,0006	-0,0028	0,0017	0,0007	0,0009	0,0040	0,0064
23	-0,0006	0,0002	0,0003	0,0026	-0,0008	0,0027	0,0009	-0,0021	0,0002	-0,0009	-0,001	-0,0016	-0,0004
24	0,0005	0,0005	-0,0002	0,0030	0,0008	0,0002	-0,0004	-0,0010	0,0017	-0,0007	0,0003	0,0034	0,0035
25	0,0073	-0,0003	0,0010	0,0126	0,0066	0,0022	0,0004	0,0025	0,0078	0,0046	0,0045	0,0052	0,0101
26	0,0047	-0,0001	0,0008	0,0068	0,0027	0,0028	-0,0004	0,0000	0,0069	0,0034	0,0040	0,0023	0,0049

EK 12. Portföy Optimizasyonu Analizinde Model 2 için hesaplanan varyans-kovaryans matrisi (devamı).

	14	15	16	17	18	19	20	21	22	23	24	25	26
1	0,0022	0,0021	0,0002	0,0026	0,0039	0,0004	0,0029	0,0003	0,0006	-0,001	0,0005	0,0073	0,0047
2	0,0005	0,0003	0,0001	0,0003	-0,0003	0,0001	0,0007	0,0005	0,0005	0,0002	0,0005	-0,0003	-0,0001
3	0,0008	0,0002	0,0003	0,0014	0,0008	0,0006	0,0008	0,0003	-0,0005	0,0003	-0,0002	0,0010	0,0008
4	-0,0013	0,0057	-0,0003	0,0011	0,0095	0,0058	0,0095	0,0009	0,0003	0,0026	0,0030	0,0126	0,0068
5	0,0003	0,0015	0,0006	0,0018	0,0035	0,0013	0,0030	0,0008	0,0005	-0,001	0,0008	0,0066	0,0027
6	0,0028	0,0025	0,0004	0,0030	0,0046	0,0021	0,0025	0,0026	0,0032	0,0027	0,0002	0,0022	0,0028
7	0,0004	-0,0006	-0,0002	-0,0003	0,0007	0,0002	0,0001	0,0007	-0,0006	0,0009	-0,0004	0,0004	-0,0004
8	0,0010	-0,0017	0,0008	0,0028	-0,0016	-0,0002	0,0003	-0,0004	-0,0028	-0,002	-0,0010	0,0025	0,0000
9	0,0036	0,0045	0,0010	0,0051	0,0054	0,0020	0,0056	0,0011	0,0017	0,0002	0,0017	0,0078	0,0069
10	0,0037	0,0005	0,0008	0,0027	0,0028	-0,0010	-0,0001	0,0004	0,0007	-0,001	-0,0007	0,0046	0,0034
11	0,0053	0,0013	0,0028	0,0073	0,0039	-0,0001	0,0037	0,0046	0,0009	-0,001	0,0003	0,0045	0,0040
12	0,0007	0,0034	0,0028	0,0045	0,0032	0,0028	0,0061	0,0031	0,0040	-0,002	0,0034	0,0052	0,0023
13	0,0013	0,0048	0,0006	0,0013	0,0070	0,0013	0,0058	0,0027	0,0064	-0,000	0,0035	0,0101	0,0049
14	0,0043	0,0020	0,0012	0,0045	0,0015	0,0013	0,0036	0,0013	0,0001	0,0009	0,0008	0,0020	0,0034
15	0,0020	0,0040	0,0005	0,0027	0,0034	0,0020	0,0050	0,0009	0,0024	0,0008	0,0023	0,0045	0,0044
16	0,0012	0,0005	0,0015	0,0025	0,0007	0,0007	0,0013	0,0009	-0,0003	-0,001	0,0004	0,0007	0,0010
17	0,0045	0,0027	0,0025	0,0095	0,0042	0,0036	0,0052	0,0023	-0,0007	0,0000	0,0001	0,0062	0,0054
18	0,0015	0,0034	0,0007	0,0042	0,0108	0,0032	0,0025	0,0029	0,0046	0,0011	-0,0007	0,0115	0,0057
19	0,0013	0,0020	0,0007	0,0036	0,0032	0,0032	0,0036	0,0009	-0,0003	0,0013	0,0005	0,0041	0,0026
20	0,0036	0,0050	0,0013	0,0052	0,0025	0,0036	0,0103	0,0017	-0,0008	0,0011	0,0042	0,0060	0,0057
21	0,0013	0,0009	0,0009	0,0023	0,0029	0,0009	0,0017	0,0028	0,0023	0,0005	0,0003	0,0020	0,0008
22	0,0001	0,0024	-0,0003	-0,0007	0,0046	-0,0003	-0,0008	0,0023	0,0088	0,0004	0,0009	0,0030	0,0009
23	0,0009	0,0008	-0,0007	0,0000	0,0011	0,0013	0,0011	0,0005	0,0004	0,0025	0,0001	-0,0004	0,0004
24	0,0008	0,0023	0,0004	0,0001	-0,0007	0,0005	0,0042	0,0003	0,0009	0,0001	0,0030	0,0003	0,0014
25	0,0020	0,0045	0,0007	0,0062	0,0115	0,0041	0,0060	0,0020	0,0030	-0,000	0,0003	0,0181	0,0084
26	0,0034	0,0044	0,0010	0,0054	0,0057	0,0026	0,0057	0,0008	0,0009	0,0004	0,0014	0,0084	0,0071

1= AKBANK, 2= AKSA, 3=ARÇELİK, 4=ASYA KAT.BANK., 5=BİM MAĞAZALAR, 6=DOĞAN HOLDİNG, 7=ENKA İNŞAAT, 8=EREĞLİ DEM-ÇEL, 9=GARANTİ BANKASI, 10=İHLAS HOLD., 11=İŞ BANKASI, 12=KARDEMİR, 13=KOÇ HOLD., 14=PETKİM, 15=SABANCI, 16=SİNPAŞ, 17=ŞİŞE CAM, 18=T. HALK BANKASI, 19=TEKFEN, 20=TOFAŞ, 21=TRKCELL, 22=TÜPRAŞ, 23=THY, 24=TÜRK TRAKTÖR, 25=VAKIFLAR BANKASI, 26=YAPI VE KREDİ BANK

EK 13. Portföy Optimizasyonu Analizinde Model 3 için hesaplanan varyans-kovaryans matrisi.

	1	2	3	4	5	6	7	8	9	10	11	12	13
1	0,0050	-0,0001	0,0014	0,0055	0,0026	0,0006	0,0002	0,0017	0,0051	0,0050	0,0044	0,0030	0,0034
2	-0,0001	0,0003	0,0006	-0,0003	-0,0001	0,0006	0,0001	0,0002	0,0002	-0,0001	0,0004	0,0007	0,0004
3	0,0014	0,0006	0,0031	0,0032	0,0015	0,0028	0,0005	0,0005	0,0033	0,0008	0,0035	0,0040	0,0029
4	0,0055	-0,0003	0,0032	0,0216	0,0043	0,0043	-0,0009	0,0001	0,0077	-0,0017	0,0076	0,0072	0,0056
5	0,0026	-0,0001	0,0015	0,0043	0,0031	-0,0002	0,0002	0,0014	0,0027	0,0013	0,0020	0,0045	0,0020
6	0,0006	0,0006	0,0028	0,0043	-0,0002	0,0066	0,0007	-0,0016	0,0037	-0,0003	0,0053	0,0010	0,0028
7	0,0002	0,0001	0,0005	-0,0009	0,0002	0,0007	0,0012	-0,0001	0,0002	0,0007	-0,000	-0,0012	0,0001
8	0,0017	0,0002	0,0005	0,0001	0,0014	-0,0016	-0,0001	0,0081	-0,0005	0,0014	-0,001	0,0048	-0,0003
9	0,0051	0,0002	0,0033	0,0077	0,0027	0,0037	0,0002	-0,0005	0,0076	0,0046	0,0077	0,0039	0,0054
10	0,0050	-0,0001	0,0008	-0,0017	0,0013	-0,0003	0,0007	0,0014	0,0046	0,0100	0,0036	0,0004	0,0028
11	0,0044	0,0004	0,0035	0,0076	0,0020	0,0053	-0,0002	-0,0009	0,0077	0,0036	0,0088	0,0044	0,0056
12	0,0030	0,0007	0,0040	0,0072	0,0045	0,0010	-0,0012	0,0048	0,0039	0,0004	0,0044	0,0130	0,0040
13	0,0034	0,0004	0,0029	0,0056	0,0020	0,0028	0,0001	-0,0003	0,0054	0,0028	0,0056	0,0040	0,0044
14	0,0022	0,0005	0,0027	0,0014	0,0003	0,0028	0,0004	0,0010	0,0040	0,0037	0,0042	0,0022	0,0031
15	0,0021	0,0003	0,0023	0,0063	0,0015	0,0025	-0,0006	-0,0017	0,0045	0,0005	0,0050	0,0036	0,0037
16	0,0028	0,0001	0,0031	0,0061	0,0022	0,0016	-0,0010	0,0010	0,0049	0,0019	0,0050	0,0061	0,0037
17	0,0018	0,0005	0,0030	0,0017	0,0008	0,0033	-0,0001	0,0023	0,0040	0,0018	0,0048	0,0037	0,0030
18	0,0039	-0,0003	0,0025	0,0071	0,0035	0,0046	0,0007	-0,0016	0,0065	0,0028	0,0069	0,0033	0,0038
19	0,0004	0,0001	0,0020	0,0035	0,0013	0,0021	0,0002	-0,0002	0,0024	-0,0010	0,0025	0,0021	0,0017
20	0,0044	0,0002	0,0032	0,0071	0,0026	0,0023	0,0005	0,0002	0,0065	0,0032	0,0059	0,0032	0,0048
21	0,0003	0,0005	0,0020	-0,0006	0,0008	0,0026	0,0007	-0,0004	0,0017	0,0004	0,0023	0,0021	0,0014
22	0,0041	0,0001	0,0029	0,0078	0,0028	0,0029	-0,0001	-0,0001	0,0061	0,0031	0,0062	0,0050	0,0045
23	0,0002	0,0003	0,0017	0,0006	-0,0010	0,0047	0,0018	-0,0029	0,0027	0,0008	0,0032	-0,0041	0,0020
24	0,0021	0,0006	0,0023	0,0046	0,0014	0,0007	-0,0007	0,0024	0,0027	0,0010	0,0029	0,0059	0,0030
25	0,0073	-0,0003	0,0034	0,0112	0,0066	0,0022	0,0004	0,0025	0,0088	0,0046	0,0081	0,0079	0,0057
26	0,0047	-0,0001	0,0028	0,0091	0,0027	0,0028	-0,0004	0,0000	0,0069	0,0034	0,0068	0,0045	0,0047

EK 13. Portföy Optimizasyonu Analizinde Model 3 için hesaplanan varyans-kovaryans matrisi (devamı).

	14	15	16	17	18	19	20	21	22	23	24	25	26
1	0,0022	0,0021	0,0028	0,0018	0,0039	0,0004	0,0044	0,0003	0,0041	0,0002	0,0021	0,0073	0,0047
2	0,0005	0,0003	0,0001	0,0005	-0,0003	0,0001	0,0002	0,0005	0,0001	0,0003	0,0006	-0,0003	-0,0001
3	0,0027	0,0023	0,0031	0,0030	0,0025	0,0020	0,0032	0,0020	0,0029	0,0017	0,0023	0,0034	0,0028
4	0,0014	0,0063	0,0061	0,0017	0,0071	0,0035	0,0071	-0,0006	0,0078	0,0006	0,0046	0,0112	0,0091
5	0,0003	0,0015	0,0022	0,0008	0,0035	0,0013	0,0026	0,0008	0,0028	-0,001	0,0014	0,0066	0,0027
6	0,0028	0,0025	0,0016	0,0033	0,0046	0,0021	0,0023	0,0026	0,0029	0,0047	0,0007	0,0022	0,0028
7	0,0004	-0,0006	-0,0010	-0,0001	0,0007	0,0002	0,0005	0,0007	-0,0001	0,0018	-0,0007	0,0004	-0,0004
8	0,0010	-0,0017	0,0010	0,0023	-0,0016	-0,0002	0,0002	-0,0004	-0,0001	-0,003	0,0024	0,0025	0,0000
9	0,0040	0,0045	0,0049	0,0040	0,0065	0,0024	0,0065	0,0017	0,0061	0,0027	0,0027	0,0088	0,0069
10	0,0037	0,0005	0,0019	0,0018	0,0028	-0,0010	0,0032	0,0004	0,0031	0,0008	0,0010	0,0046	0,0034
11	0,0042	0,0050	0,0050	0,0048	0,0069	0,0025	0,0059	0,0023	0,0062	0,0032	0,0029	0,0081	0,0068
12	0,0022	0,0036	0,0061	0,0037	0,0033	0,0021	0,0032	0,0021	0,0050	-0,004	0,0059	0,0079	0,0045
13	0,0031	0,0037	0,0037	0,0030	0,0038	0,0017	0,0048	0,0014	0,0045	0,0020	0,0030	0,0057	0,0047
14	0,0043	0,0020	0,0034	0,0040	0,0015	0,0013	0,0035	0,0013	0,0028	0,0023	0,0024	0,0020	0,0034
15	0,0020	0,0040	0,0038	0,0023	0,0034	0,0020	0,0039	0,0009	0,0039	0,0012	0,0026	0,0045	0,0044
16	0,0034	0,0038	0,0064	0,0043	0,0030	0,0028	0,0045	0,0009	0,0044	-0,000	0,0035	0,0055	0,0056
17	0,0040	0,0023	0,0043	0,0059	0,0027	0,0026	0,0038	0,0019	0,0028	0,0022	0,0023	0,0041	0,0038
18	0,0015	0,0034	0,0030	0,0027	0,0108	0,0032	0,0044	0,0029	0,0056	0,0031	-0,0005	0,0115	0,0057
19	0,0013	0,0020	0,0028	0,0026	0,0032	0,0032	0,0028	0,0009	0,0021	0,0021	0,0006	0,0041	0,0026
20	0,0035	0,0039	0,0045	0,0038	0,0044	0,0028	0,0069	0,0009	0,0050	0,0029	0,0028	0,0079	0,0060
21	0,0013	0,0009	0,0009	0,0019	0,0029	0,0009	0,0009	0,0028	0,0013	0,0013	0,0002	0,0020	0,0008
22	0,0028	0,0039	0,0044	0,0028	0,0056	0,0021	0,0050	0,0013	0,0054	0,0012	0,0028	0,0078	0,0058
23	0,0023	0,0012	-0,0004	0,0022	0,0031	0,0021	0,0029	0,0013	0,0012	0,0071	-0,0012	0,0010	0,0014
24	0,0024	0,0026	0,0035	0,0023	-0,0005	0,0006	0,0028	0,0002	0,0028	-0,001	0,0045	0,0022	0,0029
25	0,0020	0,0045	0,0055	0,0041	0,0115	0,0041	0,0079	0,0020	0,0078	0,0010	0,0022	0,0181	0,0084
26	0,0034	0,0044	0,0056	0,0038	0,0057	0,0026	0,0060	0,0008	0,0058	0,0014	0,0029	0,0084	0,0071

1= AKBANK, 2= AKSA, 3=ARÇELİK, 4=ASYA KAT.BANK., 5=BİM MAĞAZALAR, 6=DOĞAN HOLDİNG, 7=ENKA İNŞAAT, 8=EREĞLİ DEM-ÇEL, 9=GARANTİ BANKASI, 10=İHLAS HOLD., 11=İŞ BANKASI, 12=KARDEMİR, 13=KOÇ HOLD., 14=PETKİM, 15=SABANCI, 16=SİNPAŞ, 17=ŞİŞE CAM, 18=T. HALK BANKASI, 19=TEKFEN, 20=TOFAŞ, 21=TRKCELL, 22=TÜPRAŞ, 23=THY, 24=TÜRK TRAKTÖR, 25=VAKIFLAR BANKASI, 26=YAPI VE KREDİ BANK

EK 14. Portföy Optimizasyonu Analizinde Model 4 için hesaplanan varyans-kovaryans matrisi.

	1	2	3	4	5	6	7	8	9	10	11	12	13
1	0,0165	0,0054	0,01165	0,01264	0,00547	0,00783	0,0069	0,0050	0,01509	0,00829	0,01220	0,00756	0,01245
2	0,0054	0,0180	0,00844	0,00621	0,00544	0,00209	0,0109	0,0058	0,00818	0,00563	0,00793	0,00915	0,00758
3	0,0116	0,0084	0,02230	0,01327	0,00743	0,00796	0,0124	0,0084	0,01469	0,01136	0,01160	0,01184	0,01260
4	0,0126	0,0062	0,01327	0,02387	0,01386	0,00869	0,0095	0,0043	0,01740	0,01519	0,01223	0,01048	0,01165
5	0,0054	0,0054	0,00743	0,01386	0,02040	0,00337	0,0071	0,0014	0,01017	0,00985	0,00668	0,00779	0,00454
6	0,0078	0,0020	0,00796	0,00869	0,00337	0,01671	0,0053	0,0065	0,00898	0,01011	0,00854	0,00807	0,00905
7	0,0069	0,0109	0,01245	0,00952	0,00712	0,00530	0,0186	0,0092	0,00917	0,00872	0,00944	0,01297	0,01113
8	0,0050	0,0058	0,00840	0,00436	0,00149	0,00653	0,0092	0,0174	0,00583	0,00708	0,00605	0,00752	0,00833
9	0,0150	0,0081	0,01469	0,01740	0,01017	0,00898	0,0091	0,0058	0,01906	0,01120	0,01393	0,01014	0,01375
10	0,0082	0,0056	0,01136	0,01519	0,00985	0,01011	0,0087	0,0070	0,01120	0,03296	0,00862	0,01103	0,01064
11	0,0122	0,0079	0,01160	0,01223	0,00668	0,00854	0,0094	0,0060	0,01393	0,00862	0,01477	0,01074	0,01302
12	0,0075	0,0091	0,01184	0,01048	0,00779	0,00807	0,0129	0,0075	0,01014	0,01103	0,01074	0,01826	0,01141
13	0,0124	0,0075	0,01260	0,01165	0,00454	0,00905	0,0111	0,0083	0,01375	0,01064	0,01302	0,01141	0,01611
14	0,0025	0,0043	0,00447	0,01058	0,00670	0,00584	0,0043	0,0033	0,00630	0,00683	0,00532	0,00629	0,00514
15	0,0125	0,0059	0,01327	0,01345	0,00701	0,00819	0,0095	0,0072	0,01385	0,01184	0,01194	0,01041	0,01388
16	0,0107	0,0089	0,01360	0,01165	0,00679	0,01345	0,0132	0,0140	0,01279	0,01522	0,01200	0,01468	0,01319
17	0,0088	0,0069	0,01125	0,01102	0,00605	0,00688	0,0100	0,0064	0,01082	0,00895	0,00956	0,00934	0,01023
18	0,0130	0,0082	0,01440	0,01471	0,00910	0,00709	0,0100	0,0056	0,01599	0,00891	0,01236	0,01056	0,01262
19	0,0049	0,0057	0,00869	0,00764	0,00582	0,00572	0,0091	0,0052	0,00611	0,00863	0,00681	0,00908	0,00718
20	0,0109	0,0090	0,01493	0,01600	0,00995	0,00944	0,0138	0,0090	0,01416	0,01442	0,01195	0,01222	0,01281
21	0,0053	0,0036	0,00406	0,00818	0,00459	0,00182	0,0042	0,0020	0,00676	0,00424	0,00575	0,00340	0,00517
22	0,0074	0,0066	0,00817	0,00820	0,00418	0,00618	0,0095	0,0068	0,00881	0,00689	0,00780	0,00737	0,00859
23	0,0091	0,0118	0,01026	0,00970	0,00672	0,00382	0,0132	0,0045	0,01004	0,00607	0,01192	0,01128	0,01175
24	0,0063	0,0051	0,00996	0,01127	0,00596	0,00554	0,0077	0,0061	0,00933	0,01021	0,00694	0,00944	0,00826
25	0,0158	0,0081	0,01496	0,01713	0,00913	0,01010	0,0106	0,0063	0,01784	0,01079	0,01516	0,01212	0,01477
26	0,0106	0,0061	0,01241	0,01270	0,00736	0,00710	0,0087	0,0055	0,01346	0,00943	0,01164	0,00843	0,01186

EK 14. Portföy Optimizasyonu Analizinde Model 4 için hesaplanan varyans-kovaryans matrisi (devamı).

	14	15	16	17	18	19	20	21	22	23	24	25	26
1	0,0025	0,01257	0,0108	0,00880	0,01304	0,00495	0,01098	0,00535	0,00742	0,00916	0,00639	0,01584	0,01068
2	0,0044	0,00592	0,0090	0,00697	0,00820	0,00577	0,00909	0,00367	0,00665	0,01186	0,00515	0,00819	0,00618
3	0,0045	0,01327	0,0136	0,01125	0,01440	0,00869	0,01493	0,00406	0,00817	0,01026	0,00996	0,01496	0,01241
4	0,0106	0,01345	0,0117	0,01102	0,01471	0,00764	0,01600	0,00818	0,00820	0,00970	0,01127	0,01713	0,01270
5	0,0067	0,00701	0,0068	0,00605	0,00910	0,00582	0,00995	0,00459	0,00418	0,00672	0,00596	0,00913	0,00736
6	0,0058	0,00819	0,0135	0,00688	0,00709	0,00572	0,00944	0,00182	0,00618	0,00382	0,00554	0,01010	0,00710
7	0,0043	0,00953	0,0133	0,01004	0,01003	0,00914	0,01386	0,00426	0,00953	0,01322	0,00778	0,01062	0,00870
8	0,0033	0,00724	0,0141	0,00647	0,00562	0,00523	0,00901	0,00206	0,00683	0,00450	0,00612	0,00636	0,00546
9	0,0063	0,01385	0,0128	0,01082	0,01599	0,00611	0,01416	0,00676	0,00881	0,01004	0,00933	0,01784	0,01346
10	0,0068	0,01184	0,0152	0,00895	0,00891	0,00863	0,01442	0,00424	0,00689	0,00607	0,01021	0,01079	0,00943
11	0,0053	0,01194	0,0120	0,00956	0,01236	0,00681	0,01195	0,00575	0,00780	0,01192	0,00694	0,01516	0,01164
12	0,0063	0,01041	0,0147	0,00934	0,01056	0,00908	0,01222	0,00340	0,00737	0,01128	0,00944	0,01212	0,00843
13	0,0051	0,01388	0,0132	0,01023	0,01262	0,00718	0,01281	0,00517	0,00859	0,01175	0,00826	0,01477	0,01186
14	0,0199	0,00463	0,0083	0,00519	0,00606	0,00357	0,00723	0,00376	0,00229	0,00299	0,00467	0,00602	0,00644
15	0,0046	0,01610	0,0131	0,00974	0,01328	0,00682	0,01302	0,00472	0,00687	0,01004	0,00719	0,01462	0,01139
16	0,0083	0,01306	0,0296	0,00997	0,01245	0,01008	0,01701	0,00264	0,00886	0,01066	0,01022	0,01361	0,01082
17	0,0052	0,00974	0,0100	0,01442	0,00960	0,00744	0,01226	0,00498	0,00723	0,00914	0,00870	0,01194	0,00880
18	0,0061	0,01328	0,0124	0,00960	0,01947	0,00727	0,01288	0,00620	0,00700	0,01066	0,00850	0,01799	0,01375
19	0,0036	0,00682	0,0101	0,00744	0,00727	0,01277	0,01114	0,00226	0,00643	0,00754	0,00686	0,00782	0,00731
20	0,0072	0,01302	0,0170	0,01226	0,01288	0,01114	0,02116	0,00536	0,01044	0,01182	0,01076	0,01481	0,01147
21	0,0038	0,00472	0,0026	0,00498	0,00620	0,00226	0,00536	0,00715	0,00359	0,00590	0,00477	0,00676	0,00509
22	0,0023	0,00687	0,0089	0,00723	0,00700	0,00643	0,01044	0,00359	0,01039	0,00758	0,00732	0,00880	0,00639
23	0,0030	0,01004	0,0107	0,00914	0,01066	0,00754	0,01182	0,00590	0,00758	0,02608	0,00687	0,01105	0,00967
24	0,0047	0,00719	0,0102	0,00870	0,00850	0,00686	0,01076	0,00477	0,00732	0,00687	0,01710	0,00946	0,00685
25	0,0060	0,01462	0,0136	0,01194	0,01799	0,00782	0,01481	0,00676	0,00880	0,01105	0,00946	0,02207	0,01412
26	0,0064	0,01139	0,0108	0,00880	0,01375	0,00731	0,01147	0,00509	0,00639	0,00967	0,00685	0,01412	0,01416

1= AKBANK, 2= AKSA, 3=ARÇELİK, 4=ASYA KAT.BANK., 5=BİM MAĞAZALAR, 6=DOĞAN HOLDİNG, 7=ENKA İNŞAAT, 8=EREĞLİ DEM-ÇEL, 9=GARANTİ BANKASI, 10=İHLAS HOLD., 11=İŞ BANKASI, 12=KARDEMİR, 13=KOÇ HOLD., 14=PETKİM, 15=SABANCI, 16=SİNPAŞ, 17=ŞİŞE CAM, 18=T. HALK BANKASI, 19=TEKFEN, 20=TOFAŞ, 21=TURKCELL, 22=TÜPRAŞ, 23=THY, 24=TÜRK TRAKTÖR, 25=VAKIFLAR BANKASI, 26=YAPI VE KREDİ BANK

EK 15. Model 2'nin minimum beklenen deęerini bulmaya yönelik yazılmıř Lingo Programı kodları.

MODEL:

! Standart Markowitz Portföy Modeli;

SETS:

HISSE/1..26/: ORT, X;

KOVMAT(HISSE,HISSE): V;

ENDSETS

DATA:

!Veri Setleri;

!Hisse senetlerinin beklenen getirisi;

ort= 0.026130656	-0.003983803	0.003547604	-0.008740722	0.010458892
0.017698129	-0.000995595	0.055364814	0.023047892	-0.012050977
0.033218616	0.067907283	0.041290076	0.04627195	0.016478752
0.004207906	0.023681046	0.036951591	0.0144098	0.015065204
0.017118072	0.021988351	0.017838305	0.007097288	0.036815945
0.02519253;				

!Kovaryans matrisi;

V =

0.005023413	-0.000140888	0.000476716	0.002713692	0.002612888	0.00056473
0.000185901	0.001650758	0.004845735	0.00503759	0.004362204	-
0.000256407	0.004489106	0.00220746	0.002148957	0.000150182	0.002575039
0.003876636	0.000192355	0.00290067	0.000297039	0.000570823	-
0.000572058	0.000454396	0.007319977	0.00470515		
-0.000140888	0.00027841	4.36298E-05	-0.000292578	-5.74962E-05	0.000558958
0.000109912	0.000218302	2.14981E-05	-0.000146305	0.000686672	
0.000982184	0.000462604	0.000510582	0.000274901	0.000109817	
0.000250206	-0.000286428	0.000249626	0.000741492	0.000473521	
0.000497295	0.000219616	0.000499648	-0.000343902	-9.39328E-05	
0.000476716	4.36298E-05	0.00031465	0.000703806	0.000296843	0.000735624
0.000231468	0.000692649	0.000667175	0.000487482	0.001160537	
0.00035024	-0.000120798	0.000819394	0.000230291	0.000315154	
0.001362382	0.000756288	0.000467572	0.000818395	0.000338865	-
0.000521111	0.000250621	-0.000168499	0.001049042	0.0007978	
0.002713692	-0.000292578	0.000703806	0.028970912	0.005467705	0.004855524
0.000560832	-0.002383703	0.005084315	-0.006597344	-0.00408523	
0.008580179	0.007566085	-0.001271254	0.00572944	-0.000273538	

0.001135431	0.009525285	0.003611753	0.009493942	0.000943174	
0.00025655	0.002599595	0.002979147	0.012591963	0.006836138	
0.002612888	-5.74962E-05	0.000296843	0.005467705	0.003134021	-0.000243107
0.0001525	0.001449511	0.002551354	0.001343507	0.001946896	
0.003455364	0.004628314	0.000301787	0.001523734	0.000626516	
0.001822325	0.00354882	0.000504839	0.003015339	0.000780672	
0.000486325	-0.000825181	0.000840822	0.006622802	0.002684461	
0.00056473	0.000558958	0.000735624	0.004855524	-0.000243107	0.006580887
0.000729871	-0.001557283	0.002672368	-0.000347999	0.003431857	
0.002547685	0.001491171	0.002842481	0.002488566	0.000428084	
0.003014125	0.004606692	0.002350419	0.002520601	0.002634373	
0.003174155	0.002654438	0.000225717	0.002158562	0.002803825	
0.000185901	0.000109912	0.000231468	0.000560832	0.0001525	0.000729871
0.00124143	-0.000138651	-0.000405919	0.000701927	0.001232307	-
0.001476532	0.000104594	0.00035273	-0.000606634	-0.000241318	-0.000300051
0.000689361	0.000132546	0.000145137	0.000739655	-0.00060772	
0.000881164	-0.00042737	0.000358078	-0.000444691		
0.001650758	0.000218302	0.000692649	-0.002383703	0.001449511	-0.001557283
-0.000138651	0.008142923	-0.000477912	0.00136368	0.003127486	
0.003185566	-0.002008925	0.001027133	-0.001654387	0.000817363	
0.002763924	-0.001606082	-0.000454054	0.000308223	-0.000426763	-
0.002842872	-0.002146081	-0.001018635	0.002495204	2.44845E-05	
0.004845735	2.14981E-05	0.000667175	0.005084315	0.002551354	0.002672368
-0.000405919	-0.000477912	0.007084035	0.00430837	0.005140778	
0.002057283	0.005752098	0.003642861	0.004465374	0.001044201	
0.005126558	0.005384346	0.001676177	0.005636039	0.001149702	
0.001656112	0.000226519	0.001720261	0.007817361	0.006910972	
0.00503759	-0.000146305	0.000487482	-0.006597344	0.001343507	-0.000347999
0.000701927	0.00136368	0.00430837	0.009988396	0.007023798	-
0.004307125	0.003470208	0.003738076	0.00052562	0.000756747	0.002673951
0.002766213	-0.000865312	-7.12892E-05	0.00037781	0.000701867	-
0.000883555	-0.000729301	0.004608993	0.003441387		
0.004362204	0.000686672	0.001160537	-0.00408523	0.001946896	0.003431857
0.001232307	0.003127486	0.005140778	0.007023798	0.015794048	
0.003030518	0.003998592	0.005309697	0.001258098	0.002838728	
0.007274123	0.003914912	0.000729423	0.003747218	0.004623983	
0.000860183	-0.001272848	0.000259045	0.004509512	0.004027344	
-0.000256407	0.000982184	0.00035024	0.008580179	0.003455364	0.002547685
-0.001476532	0.003185566	0.002057283	-0.004307125	0.003030518	
0.015974407	0.006207099	0.000729029	0.003416195	0.002817676	
0.004472949	0.003226878	0.002218629	0.006126244	0.003056881	
0.003967929	-0.001613783	0.003369326	0.005239496	0.002296112	
0.004489106	0.000462604	-0.000120798	0.007566085	0.004628314	0.001491171
0.000104594	-0.002008925	0.005752098	0.003470208	0.003998592	

0.006207099	0.012601248	0.001332145	0.004797642	0.000630355	
0.001342817	0.007022697	0.000986732	0.005766858	0.002693151	
0.006376423	-0.000395289	0.003482849	0.01012058	0.00492583	
0.00220746	0.000510582	0.000819394	-0.001271254	0.000301787	0.002842481
0.00035273	0.001027133	0.003642861	0.003738076	0.005309697	
0.000729029	0.001332145	0.004290755	0.002016416	0.001157126	
0.004511742	0.001520006	0.001423924	0.003590522	0.001280681	
0.000146102	0.000919333	0.000841841	0.002003435	0.0033872	
0.002148957	0.000274901	0.000230291	0.00572944	0.001523734	0.002488566
-0.000606634	-0.001654387	0.004465374	0.00052562	0.001258098	
0.003416195	0.004797642	0.002016416	0.004006799	0.00046838	
0.0027336	0.003368156	0.001740403	0.004955896	0.000915497	
0.002438619	0.000822739	0.002328496	0.004548802	0.004396649	
0.000150182	0.000109817	0.000315154	-0.000273538	0.000626516	0.000428084
-0.000241318	0.000817363	0.001044201	0.000756747	0.002838728	
0.002817676	0.000630355	0.001157126	0.00046838	0.00152219	
0.002527075	0.000708451	0.000470142	0.001322959	0.000889035	-
0.000283702	-0.000690693	0.000392952	0.000656371	0.000958917	
0.002575039	0.000250206	0.001362382	0.001135431	0.001822325	0.003014125
-0.000300051	0.002763924	0.005126558	0.002673951	0.007274123	
0.004472949	0.001342817	0.004511742	0.0027336	0.002527075	
0.009457144	0.004241716	0.002751414	0.00520136	0.002338827	-
0.000680537	-3.49897E-05	8.77014E-05	0.006240807	0.005375843	
0.003876636	-0.000286428	0.000756288	0.009525285	0.00354882	0.004606692
0.000689361	-0.001606082	0.005384346	0.002766213	0.003914912	
0.003226878	0.007022697	0.001520006	0.003368156	0.000708451	
0.004241716	0.01076171	0.002089305	0.002510087	0.002882013	
0.00459569	0.001072682	-0.000689683	0.011520813	0.005660008	
0.000192355	0.000249626	0.000467572	0.003611753	0.000504839	0.002350419
0.000132546	-0.000454054	0.001676177	-0.000865312	0.000729423	
0.002218629	0.000986732	0.001423924	0.001740403	0.000470142	
0.002751414	0.002089305	0.001730483	0.002891613	0.00105937	
0.000454956	0.00123299	0.000619922	0.00217514	0.001942884	
0.00290067	0.000741492	0.000818395	0.009493942	0.003015339	0.002520601
0.000145137	0.000308223	0.005636039	-7.12892E-05	0.003747218	
0.006126244	0.005766858	0.003590522	0.004955896	0.001322959	
0.00520136	0.002510087	0.002891613	0.010258845	0.001651056	-
0.000795679	0.001107528	0.004190488	0.006017575	0.005725106	
0.000297039	0.000473521	0.000338865	0.000943174	0.000780672	0.002634373
0.000739655	-0.000426763	0.001149702	0.00037781	0.004623983	
0.003056881	0.002693151	0.001280681	0.000915497	0.000889035	
0.002338827	0.002882013	0.00105937	0.001651056	0.00284649	
0.002301421	0.000473259	0.000337061	0.002015147	0.000791982	

0.000570823 0.000497295 -0.000521111 0.00025655 0.000486325 0.003174155
-0.00060772 -0.002842872 0.001656112 0.000701867 0.000860183
0.003967929 0.006376423 0.000146102 0.002438619 -0.000283702 -
0.000680537 0.00459569 0.000454956 -0.000795679 0.002301421 0.008770797
0.000393263 0.000866913 0.003021641 0.000926186

-0.000572058 0.000219616 0.000250621 0.002599595 -0.000825181 0.002654438
0.000881164 -0.002146081 0.000226519 -0.000883555 -0.001272848 -
0.001613783 -0.000395289 0.000919333 0.000822739 -0.000690693 -3.49897E-05
0.001072682 0.00123299 0.001107528 0.000473259 0.000393263
0.002487537 9.1602E-05 -0.000390717 0.000421773

0.000454396 0.000499648 -0.000168499 0.002979147 0.000840822 0.000225717
-0.00042737 -0.001018635 0.001720261 -0.000729301 0.000259045
0.003369326 0.003482849 0.000841841 0.002328496 0.000392952
8.77014E-05 -0.000689683 0.000619922 0.004190488 0.000337061
0.000866913 9.1602E-05 0.003030188 0.000273438 0.001386952

0.007319977 -0.000343902 0.001049042 0.012591963 0.006622802 0.002158562
0.000358078 0.002495204 0.007817361 0.004608993 0.004509512
0.005239496 0.01012058 0.002003435 0.004548802 0.000656371
0.006240807 0.011520813 0.00217514 0.006017575 0.002015147
0.003021641 -0.000390717 0.000273438 0.018094325 0.008399339

0.00470515 -9.39328E-05 0.0007978 0.006836138 0.002684461 0.002803825
-0.000444691 2.44845E-05 0.006910972 0.003441387 0.004027344
0.002296112 0.00492583 0.0033872 0.004396649 0.000958917
0.005375843 0.005660008 0.001942884 0.005725106 0.000791982
0.000926186 0.000421773 0.001386952 0.008399339 0.007089852;

ENDDATA

! Model;

! Amaç: Portföy Varyansı Minimizasyonu;

[VAR] MIN = @SUM(KOVMAT(L,J): V(L,J)*X(I)*X(J));

z=@SUM(HISSE: ORT*X);

!Portföydeki Hisselerin Ağırlıkları Toplamı 1 Olmalı Kısıtı;

[YUZDEYUZ] @SUM(HISSE: X) = 1;

END

EK 16. Model 2'nin maksimum beklenen deęerini bulmaya ynelik yazılmıř Lingo Programı kodları.

MODEL:

! Standart Markowitz Portfy Modeli;

SETS:

HISSE/1..26/: ORT, X;

KOVMAT(HISSE,HISSE): V;

ENDSETS

DATA:

!Veri Setleri;

!Hisse senetlerinin beklenen getirisi;

ort= 0.026130656	-0.003983803	0.003547604	-0.008740722	0.010458892
0.017698129	-0.000995595	0.055364814	0.023047892	-0.012050977
0.033218616	0.067907283	0.041290076	0.04627195	0.016478752
0.004207906	0.023681046	0.036951591	0.0144098	0.015065204
0.017118072	0.021988351	0.017838305	0.007097288	0.036815945
0.02519253;				

!Kovaryans matrisi;

V =

0.005023413	-0.000140888	0.000476716	0.002713692	0.002612888	0.00056473
0.000185901	0.001650758	0.004845735	0.00503759	0.004362204	-
0.000256407	0.004489106	0.00220746	0.002148957	0.000150182	0.002575039
0.003876636	0.000192355	0.00290067	0.000297039	0.000570823	-
0.000572058	0.000454396	0.007319977	0.00470515		
-0.000140888	0.00027841	4.36298E-05	-0.000292578	-5.74962E-05	0.000558958
0.000109912	0.000218302	2.14981E-05	-0.000146305	0.000686672	
0.000982184	0.000462604	0.000510582	0.000274901	0.000109817	
0.000250206	-0.000286428	0.000249626	0.000741492	0.000473521	
0.000497295	0.000219616	0.000499648	-0.000343902	-9.39328E-05	
0.000476716	4.36298E-05	0.00031465	0.000703806	0.000296843	0.000735624
0.000231468	0.000692649	0.000667175	0.000487482	0.001160537	
0.00035024	-0.000120798	0.000819394	0.000230291	0.000315154	
0.001362382	0.000756288	0.000467572	0.000818395	0.000338865	-
0.000521111	0.000250621	-0.000168499	0.001049042	0.0007978	
0.002713692	-0.000292578	0.000703806	0.028970912	0.005467705	0.004855524
0.000560832	-0.002383703	0.005084315	-0.006597344	-0.00408523	
0.008580179	0.007566085	-0.001271254	0.00572944	-0.000273538	

0.001135431	0.009525285	0.003611753	0.009493942	0.000943174	
0.00025655	0.002599595	0.002979147	0.012591963	0.006836138	
0.002612888	-5.74962E-05	0.000296843	0.005467705	0.003134021	-0.000243107
0.0001525	0.001449511	0.002551354	0.001343507	0.001946896	
0.003455364	0.004628314	0.000301787	0.001523734	0.000626516	
0.001822325	0.00354882	0.000504839	0.003015339	0.000780672	
0.000486325	-0.000825181	0.000840822	0.006622802	0.002684461	
0.00056473	0.000558958	0.000735624	0.004855524	-0.000243107	0.006580887
0.000729871	-0.001557283	0.002672368	-0.000347999	0.003431857	
0.002547685	0.001491171	0.002842481	0.002488566	0.000428084	
0.003014125	0.004606692	0.002350419	0.002520601	0.002634373	
0.003174155	0.002654438	0.000225717	0.002158562	0.002803825	
0.000185901	0.000109912	0.000231468	0.000560832	0.0001525	0.000729871
0.00124143	-0.000138651	-0.000405919	0.000701927	0.001232307	-
0.001476532	0.000104594	0.00035273	-0.000606634	-0.000241318	-0.000300051
0.000689361	0.000132546	0.000145137	0.000739655	-0.00060772	
0.000881164	-0.00042737	0.000358078	-0.000444691		
0.001650758	0.000218302	0.000692649	-0.002383703	0.001449511	-0.001557283
-0.000138651	0.008142923	-0.000477912	0.00136368	0.003127486	
0.003185566	-0.002008925	0.001027133	-0.001654387	0.000817363	
0.002763924	-0.001606082	-0.000454054	0.000308223	-0.000426763	-
0.002842872	-0.002146081	-0.001018635	0.002495204	2.44845E-05	
0.004845735	2.14981E-05	0.000667175	0.005084315	0.002551354	0.002672368
-0.000405919	-0.000477912	0.007084035	0.00430837	0.005140778	
0.002057283	0.005752098	0.003642861	0.004465374	0.001044201	
0.005126558	0.005384346	0.001676177	0.005636039	0.001149702	
0.001656112	0.000226519	0.001720261	0.007817361	0.006910972	
0.00503759	-0.000146305	0.000487482	-0.006597344	0.001343507	-0.000347999
0.000701927	0.00136368	0.00430837	0.009988396	0.007023798	-
0.004307125	0.003470208	0.003738076	0.00052562	0.000756747	0.002673951
0.002766213	-0.000865312	-7.12892E-05	0.00037781	0.000701867	-
0.000883555	-0.000729301	0.004608993	0.003441387		
0.004362204	0.000686672	0.001160537	-0.00408523	0.001946896	0.003431857
0.001232307	0.003127486	0.005140778	0.007023798	0.015794048	
0.003030518	0.003998592	0.005309697	0.001258098	0.002838728	
0.007274123	0.003914912	0.000729423	0.003747218	0.004623983	
0.000860183	-0.001272848	0.000259045	0.004509512	0.004027344	
-0.000256407	0.000982184	0.00035024	0.008580179	0.003455364	0.002547685
-0.001476532	0.003185566	0.002057283	-0.004307125	0.003030518	
0.015974407	0.006207099	0.000729029	0.003416195	0.002817676	
0.004472949	0.003226878	0.002218629	0.006126244	0.003056881	
0.003967929	-0.001613783	0.003369326	0.005239496	0.002296112	
0.004489106	0.000462604	-0.000120798	0.007566085	0.004628314	0.001491171
0.000104594	-0.002008925	0.005752098	0.003470208	0.003998592	

0.006207099	0.012601248	0.001332145	0.004797642	0.000630355	
0.001342817	0.007022697	0.000986732	0.005766858	0.002693151	
0.006376423	-0.000395289	0.003482849	0.01012058	0.00492583	
0.00220746	0.000510582	0.000819394	-0.001271254	0.000301787	0.002842481
0.00035273	0.001027133	0.003642861	0.003738076	0.005309697	
0.000729029	0.001332145	0.004290755	0.002016416	0.001157126	
0.004511742	0.001520006	0.001423924	0.003590522	0.001280681	
0.000146102	0.000919333	0.000841841	0.002003435	0.0033872	
0.002148957	0.000274901	0.000230291	0.00572944	0.001523734	0.002488566
-0.000606634	-0.001654387	0.004465374	0.00052562	0.001258098	
0.003416195	0.004797642	0.002016416	0.004006799	0.00046838	
0.0027336	0.003368156	0.001740403	0.004955896	0.000915497	
0.002438619	0.000822739	0.002328496	0.004548802	0.004396649	
0.000150182	0.000109817	0.000315154	-0.000273538	0.000626516	0.000428084
-0.000241318	0.000817363	0.001044201	0.000756747	0.002838728	
0.002817676	0.000630355	0.001157126	0.00046838	0.00152219	
0.002527075	0.000708451	0.000470142	0.001322959	0.000889035	-
0.000283702	-0.000690693	0.000392952	0.000656371	0.000958917	
0.002575039	0.000250206	0.001362382	0.001135431	0.001822325	0.003014125
-0.000300051	0.002763924	0.005126558	0.002673951	0.007274123	
0.004472949	0.001342817	0.004511742	0.0027336	0.002527075	
0.009457144	0.004241716	0.002751414	0.00520136	0.002338827	-
0.000680537	-3.49897E-05	8.77014E-05	0.006240807	0.005375843	
0.003876636	-0.000286428	0.000756288	0.009525285	0.00354882	0.004606692
0.000689361	-0.001606082	0.005384346	0.002766213	0.003914912	
0.003226878	0.007022697	0.001520006	0.003368156	0.000708451	
0.004241716	0.01076171	0.002089305	0.002510087	0.002882013	
0.00459569	0.001072682	-0.000689683	0.011520813	0.005660008	
0.000192355	0.000249626	0.000467572	0.003611753	0.000504839	0.002350419
0.000132546	-0.000454054	0.001676177	-0.000865312	0.000729423	
0.002218629	0.000986732	0.001423924	0.001740403	0.000470142	
0.002751414	0.002089305	0.001730483	0.002891613	0.00105937	
0.000454956	0.00123299	0.000619922	0.00217514	0.001942884	
0.00290067	0.000741492	0.000818395	0.009493942	0.003015339	0.002520601
0.000145137	0.000308223	0.005636039	-7.12892E-05	0.003747218	
0.006126244	0.005766858	0.003590522	0.004955896	0.001322959	
0.00520136	0.002510087	0.002891613	0.010258845	0.001651056	-
0.000795679	0.001107528	0.004190488	0.006017575	0.005725106	
0.000297039	0.000473521	0.000338865	0.000943174	0.000780672	0.002634373
0.000739655	-0.000426763	0.001149702	0.00037781	0.004623983	
0.003056881	0.002693151	0.001280681	0.000915497	0.000889035	
0.002338827	0.002882013	0.00105937	0.001651056	0.00284649	
0.002301421	0.000473259	0.000337061	0.002015147	0.000791982	

0.000570823 0.000497295 -0.000521111 0.00025655 0.000486325 0.003174155
-0.00060772 -0.002842872 0.001656112 0.000701867 0.000860183
0.003967929 0.006376423 0.000146102 0.002438619 -0.000283702 -
0.000680537 0.00459569 0.000454956 -0.000795679 0.002301421 0.008770797
0.000393263 0.000866913 0.003021641 0.000926186

-0.000572058 0.000219616 0.000250621 0.002599595 -0.000825181 0.002654438
0.000881164 -0.002146081 0.000226519 -0.000883555 -0.001272848 -
0.001613783 -0.000395289 0.000919333 0.000822739 -0.000690693 -3.49897E-05
0.001072682 0.00123299 0.001107528 0.000473259 0.000393263
0.002487537 9.1602E-05 -0.000390717 0.000421773

0.000454396 0.000499648 -0.000168499 0.002979147 0.000840822 0.000225717
-0.00042737 -0.001018635 0.001720261 -0.000729301 0.000259045
0.003369326 0.003482849 0.000841841 0.002328496 0.000392952
8.77014E-05 -0.000689683 0.000619922 0.004190488 0.000337061
0.000866913 9.1602E-05 0.003030188 0.000273438 0.001386952

0.007319977 -0.000343902 0.001049042 0.012591963 0.006622802 0.002158562
0.000358078 0.002495204 0.007817361 0.004608993 0.004509512
0.005239496 0.01012058 0.002003435 0.004548802 0.000656371
0.006240807 0.011520813 0.00217514 0.006017575 0.002015147
0.003021641 -0.000390717 0.000273438 0.018094325 0.008399339

0.00470515 -9.39328E-05 0.0007978 0.006836138 0.002684461 0.002803825
-0.000444691 2.44845E-05 0.006910972 0.003441387 0.004027344
0.002296112 0.00492583 0.0033872 0.004396649 0.000958917
0.005375843 0.005660008 0.001942884 0.005725106 0.000791982
0.000926186 0.000421773 0.001386952 0.008399339 0.007089852;

ENDDATA

! Model;

! Amaç: Portföy Beklenen Getiri Maksimizasyonu;

mAX=@SUM(HISSSE: ORT*X);

!Portföydeki Hisselerin Ağırlıkları Toplamı 1 Olmalı Kısıtı;

[YUZDEYUZ] @SUM(HISSSE: X) = 1;

END

EK 17. Model 2'nin 0,01953451 beklenen getiri düzeyindeki minimum varyans değerini bulmak amacıyla yazılan Lingo Programı kodları.

MODEL:

! Standart Markowitz Portföy Modeli;

SETS:

HISSE/1..26/: ORT, X;

KOVMAT(HISSE,HISSE): V;

ENDSETS

DATA:

!Veri Setleri;

!Hisse senetlerinin beklenen getirisi;

ORT = 0.026130656 -0.003983803 0.003547604 -0.008740722 0.010458892
0.017698129 -0.000995595 0.055364814 0.023047892 -0.012050977
0.033218616 0.067907283 0.041290076 0.04627195 0.016478752
0.004207906 0.023681046 0.036951591 0.0144098 0.015065204
0.017118072 0.021988351 0.017838305 0.007097288 0.036815945
0.02519253;

!Kovaryans matrisi;

V =

0.005023413 -0.000140888 0.000476716 0.002713692 0.002612888 0.00056473
0.000185901 0.001650758 0.004845735 0.00503759 0.004362204 -
0.000256407 0.004489106 0.00220746 0.002148957 0.000150182 0.002575039
0.003876636 0.000192355 0.00290067 0.000297039 0.000570823 -
0.000572058 0.000454396 0.007319977 0.00470515
-0.000140888 0.00027841 4.36298E-05 -0.000292578 -5.74962E-05 0.000558958
0.000109912 0.000218302 2.14981E-05 -0.000146305 0.000686672
0.000982184 0.000462604 0.000510582 0.000274901 0.000109817
0.000250206 -0.000286428 0.000249626 0.000741492 0.000473521
0.000497295 0.000219616 0.000499648 -0.000343902 -9.39328E-05
0.000476716 4.36298E-05 0.00031465 0.000703806 0.000296843 0.000735624
0.000231468 0.000692649 0.000667175 0.000487482 0.001160537
0.00035024 -0.000120798 0.000819394 0.000230291 0.000315154
0.001362382 0.000756288 0.000467572 0.000818395 0.000338865 -
0.000521111 0.000250621 -0.000168499 0.001049042 0.0007978
0.002713692 -0.000292578 0.000703806 0.028970912 0.005467705 0.004855524
0.000560832 -0.002383703 0.005084315 -0.006597344 -0.00408523
0.008580179 0.007566085 -0.001271254 0.00572944 -0.000273538
0.001135431 0.009525285 0.003611753 0.009493942 0.000943174
0.00025655 0.002599595 0.002979147 0.012591963 0.006836138
0.002612888 -5.74962E-05 0.000296843 0.005467705 0.003134021 -0.000243107
0.0001525 0.001449511 0.002551354 0.001343507 0.001946896
0.003455364 0.004628314 0.000301787 0.001523734 0.000626516
0.001822325 0.00354882 0.000504839 0.003015339 0.000780672
0.000486325 -0.000825181 0.000840822 0.006622802 0.002684461
0.00056473 0.000558958 0.000735624 0.004855524 -0.000243107 0.006580887
0.000729871 -0.001557283 0.002672368 -0.000347999 0.003431857
0.002547685 0.001491171 0.002842481 0.002488566 0.000428084
0.003014125 0.004606692 0.002350419 0.002520601 0.002634373
0.003174155 0.002654438 0.000225717 0.002158562 0.002803825

0.000185901 0.000109912 0.000231468 0.000560832 0.0001525 0.000729871
0.00124143 -0.000138651 -0.000405919 0.000701927 0.001232307 -
0.001476532 0.000104594 0.00035273 -0.000606634 -0.000241318 -0.000300051
0.000689361 0.000132546 0.000145137 0.000739655 -0.00060772
0.000881164 -0.00042737 0.000358078 -0.000444691
0.001650758 0.000218302 0.000692649 -0.002383703 0.001449511 -0.001557283
-0.000138651 0.008142923 -0.000477912 0.00136368 0.003127486
0.003185566 -0.002008925 0.001027133 -0.001654387 0.000817363
0.002763924 -0.001606082 -0.000454054 0.000308223 -0.000426763 -
0.002842872 -0.002146081 -0.001018635 0.002495204 2.44845E-05
0.004845735 2.14981E-05 0.000667175 0.005084315 0.002551354 0.002672368
-0.000405919 -0.000477912 0.007084035 0.00430837 0.005140778
0.002057283 0.005752098 0.003642861 0.004465374 0.001044201
0.005126558 0.005384346 0.001676177 0.005636039 0.001149702
0.001656112 0.000226519 0.001720261 0.007817361 0.006910972
0.00503759 -0.000146305 0.000487482 -0.006597344 0.001343507 -0.000347999
0.000701927 0.00136368 0.00430837 0.009988396 0.007023798 -
0.004307125 0.003470208 0.003738076 0.00052562 0.000756747 0.002673951
0.002766213 -0.000865312 -7.12892E-05 0.00037781 0.000701867 -
0.000883555 -0.000729301 0.004608993 0.003441387
0.004362204 0.000686672 0.001160537 -0.00408523 0.001946896 0.003431857
0.001232307 0.003127486 0.005140778 0.007023798 0.015794048
0.003030518 0.003998592 0.005309697 0.001258098 0.002838728
0.007274123 0.003914912 0.000729423 0.003747218 0.004623983
0.000860183 -0.001272848 0.000259045 0.004509512 0.004027344
-0.000256407 0.000982184 0.00035024 0.008580179 0.003455364 0.002547685
-0.001476532 0.003185566 0.002057283 -0.004307125 0.003030518
0.015974407 0.006207099 0.000729029 0.003416195 0.002817676
0.004472949 0.003226878 0.002218629 0.006126244 0.003056881
0.003967929 -0.001613783 0.003369326 0.005239496 0.002296112
0.004489106 0.000462604 -0.000120798 0.007566085 0.004628314 0.001491171
0.000104594 -0.002008925 0.005752098 0.003470208 0.003998592
0.006207099 0.012601248 0.001332145 0.004797642 0.000630355
0.001342817 0.007022697 0.000986732 0.005766858 0.002693151
0.006376423 -0.000395289 0.003482849 0.01012058 0.00492583
0.00220746 0.000510582 0.000819394 -0.001271254 0.000301787 0.002842481
0.00035273 0.001027133 0.003642861 0.003738076 0.005309697
0.000729029 0.001332145 0.004290755 0.002016416 0.001157126
0.004511742 0.001520006 0.001423924 0.003590522 0.001280681
0.000146102 0.000919333 0.000841841 0.002003435 0.0033872
0.002148957 0.000274901 0.000230291 0.00572944 0.001523734 0.002488566
-0.000606634 -0.001654387 0.004465374 0.00052562 0.001258098
0.003416195 0.004797642 0.002016416 0.004006799 0.00046838
0.0027336 0.003368156 0.001740403 0.004955896 0.000915497
0.002438619 0.000822739 0.002328496 0.004548802 0.004396649
0.000150182 0.000109817 0.000315154 -0.000273538 0.000626516 0.000428084
-0.000241318 0.000817363 0.001044201 0.000756747 0.002838728
0.002817676 0.000630355 0.001157126 0.00046838 0.00152219
0.002527075 0.000708451 0.000470142 0.001322959 0.000889035 -
0.000283702 -0.000690693 0.000392952 0.000656371 0.000958917

0.002575039 0.000250206 0.001362382 0.001135431 0.001822325 0.003014125
-0.000300051 0.002763924 0.005126558 0.002673951 0.007274123
0.004472949 0.001342817 0.004511742 0.0027336 0.002527075
0.009457144 0.004241716 0.002751414 0.00520136 0.002338827 -
0.000680537 -3.49897E-05 8.77014E-05 0.006240807 0.005375843
0.003876636 -0.000286428 0.000756288 0.009525285 0.00354882 0.004606692
0.000689361 -0.001606082 0.005384346 0.002766213 0.003914912
0.003226878 0.007022697 0.001520006 0.003368156 0.000708451
0.004241716 0.01076171 0.002089305 0.002510087 0.002882013
0.00459569 0.001072682 -0.000689683 0.011520813 0.005660008
0.000192355 0.000249626 0.000467572 0.003611753 0.000504839 0.002350419
0.000132546 -0.000454054 0.001676177 -0.000865312 0.000729423
0.002218629 0.000986732 0.001423924 0.001740403 0.000470142
0.002751414 0.002089305 0.001730483 0.002891613 0.00105937
0.000454956 0.00123299 0.000619922 0.00217514 0.001942884
0.00290067 0.000741492 0.000818395 0.009493942 0.003015339 0.002520601
0.000145137 0.000308223 0.005636039 -7.12892E-05 0.003747218
0.006126244 0.005766858 0.003590522 0.004955896 0.001322959
0.00520136 0.002510087 0.002891613 0.010258845 0.001651056 -
0.000795679 0.001107528 0.004190488 0.006017575 0.005725106
0.000297039 0.000473521 0.000338865 0.000943174 0.000780672 0.002634373
0.000739655 -0.000426763 0.001149702 0.00037781 0.004623983
0.003056881 0.002693151 0.001280681 0.000915497 0.000889035
0.002338827 0.002882013 0.00105937 0.001651056 0.00284649
0.002301421 0.000473259 0.000337061 0.002015147 0.000791982
0.000570823 0.000497295 -0.000521111 0.00025655 0.000486325 0.003174155
-0.00060772 -0.002842872 0.001656112 0.000701867 0.000860183
0.003967929 0.006376423 0.000146102 0.002438619 -0.000283702 -
0.000680537 0.00459569 0.000454956 -0.000795679 0.002301421 0.008770797
0.000393263 0.000866913 0.003021641 0.000926186
-0.000572058 0.000219616 0.000250621 0.002599595 -0.000825181 0.002654438
0.000881164 -0.002146081 0.000226519 -0.000883555 -0.001272848 -
0.001613783 -0.000395289 0.000919333 0.000822739 -0.000690693 -3.49897E-05
0.001072682 0.00123299 0.001107528 0.000473259 0.000393263
0.002487537 9.1602E-05 -0.000390717 0.000421773
0.000454396 0.000499648 -0.000168499 0.002979147 0.000840822 0.000225717
-0.00042737 -0.001018635 0.001720261 -0.000729301 0.000259045
0.003369326 0.003482849 0.000841841 0.002328496 0.000392952
8.77014E-05 -0.000689683 0.000619922 0.004190488 0.000337061
0.000866913 9.1602E-05 0.003030188 0.000273438 0.001386952
0.007319977 -0.000343902 0.001049042 0.012591963 0.006622802 0.002158562
0.000358078 0.002495204 0.007817361 0.004608993 0.004509512
0.005239496 0.01012058 0.002003435 0.004548802 0.000656371
0.006240807 0.011520813 0.00217514 0.006017575 0.002015147
0.003021641 -0.000390717 0.000273438 0.018094325 0.008399339
0.00470515 -9.39328E-05 0.0007978 0.006836138 0.002684461 0.002803825
-0.000444691 2.44845E-05 0.006910972 0.003441387 0.004027344
0.002296112 0.00492583 0.0033872 0.004396649 0.000958917
0.005375843 0.005660008 0.001942884 0.005725106 0.000791982
0.000926186 0.000421773 0.001386952 0.008399339 0.007089852;

!Portföyün hedeflenen getirisi;

```
GETIRI = 0.01953451;  
ENDDATA  
! Model;  
! Amaç: Portföy Varyansı Minimizasyonu;  
[VAR] MIN = @SUM( KOVMAT(I,J): V(I,J)*X(I)*X(J));  
!Hedeflenen Portföy Getirisi Kısıtı;  
[KAZANC] @SUM( HISSE: ORT*X) >= GETIRI;  
!Portföydeki Hisselerin Ağırlıkları Toplamı 1 Olmalı Kısıtı;  
[YUZDEYUZ] @SUM( HISSE: X) = 1;  
END
```



ÖZGEÇMİŞ

Adı Soyadı : Merve ŞİŞCİ
Doğum Tarihi : 17.03.1989
Ünvanı : Araştırma Görevlisi

Öğrenim Durumu:

Derece	Bölüm/Program	Üniversite	Yıl
Lisans	Endüstri Mühendisliği	Sakarya Üniversitesi	2008-2013
Y.Lisans	Endüstri Mühendisliği	Dumlupınar Üniversitesi	2014-

Çalıştığı Kurum : Dumlupınar Üniversitesi
Mühendislik Fakültesi
Endüstri Mühendisliği