

**YATIRIM FONU KAPANIŞ FİYATININ (NET AKTİF  
DEĞERİNİN) VE PERFORMANSININ FON PORTFÖY  
DAĞILIMINDAN FAYDALANILARAK TAHMİN  
EDİLMESİ**

**Ümit YILMAZ**



T.C.  
BURSA ULUDAĞ ÜNİVERSİTESİ  
FEN BİLİMLERİ ENSTİTÜSÜ

**YATIRIM FONU KAPANIŞ FİYATININ (NET AKTİF DEĞERİNİN) VE  
PERFORMANSININ FON PORTFÖY DAĞILIMINDAN FAYDALANILARAK  
TAHMİN EDİLMESİ**

Ümit YILMAZ  
0000-0003-4268-8598

Doç. Dr. Âli Yurdun ORBAK  
(Danışman)

DOKTORA TEZİ  
ENDÜSTRİ MÜHENDİSLİĞİ ANABİLİM DALI

BURSA – 2022  
Her Hakkı Saklıdır

## ÖZET

Doktora Tezi

### YATIRIM FONU KAPANIŞ FİYATININ (NET AKTİF DEĞERİNİN) VE PERFORMANSININ FON PORTFÖY DAĞILIMINDAN FAYDALANILARAK TAHMİN EDİLMESİ

**Ümit YILMAZ**

Bursa Uludağ Üniversitesi  
Fen Bilimleri Enstitüsü  
Endüstri Mühendisliği Anabilim Dalı

**Danışman:** Doç. Dr. Âli Yurdun ORBAK

Yatırım fonları, profesyonel bir şekilde yönetilen ve yatırımcıların paralarını bir araya getirerek çeşitli yatırım araçlarına yatırım yaparak yatırımlarını çeşitlendirmek suretiyle riski tabana yayan önemli finansal yatırım türlerinden birisidir. Yatırım fonlarının sayısı son yıllarda giderek artmaktadır. Bu gerçek, belirli yatırım fonlarının seçilmesinin, aynı yatırım evreninde faaliyet gösteren fonlar hakkında bilgi toplamak ve analiz etmek açısından önemli bir yatırımcı çabası gerektirdiğini göstermektedir.

Yatırım fonlarının kapanış fiyatlarının doğru bir şekilde tahmin edilmesi yatırımcılar açısından giderek daha önemli bir konu haline gelmiştir. Yatırım fonlarının gelecek performanslarının doğru tahminini sağlayan modellerin geliştirilmesi ile yatırım fonu yatırımcılarına büyük destek sağlanacaktır. Bu modellerin kullanımı, orta-uzun vadede yatırım yapmak isteyen yatırımcılar için uygun yatırım fonu seçimini kolaylaştıracaktır.

Bu tez çalışmasının amacı, Yapay Sinir Ağları (YSA) ve Doğrusal Olmayan Dışsal Girdili Otopregresif Ağ (NARX) kullanarak, fon portföy dağılımı ve performans değerlendirme yöntemleri değerleri yardımıyla bir menkul kıymet yatırım fonunun kapanış fiyatını doğru tahmin etmektir. Çalışmada yapılan analiz, yatırımcılara yararlı bir bakış açısı sağlayacak ve yatırımcıların yatırım fonu hakkında daha iyi kararlar almasına yardımcı olacaktır. Bu sayede yatırımcıların getirileri artacak, fon seçimi için sarf edilen efor ise azalacaktır.

**Anahtar Kelimeler:** Yatırım fonu, portföy dağılımı, performans değerlendirme yöntemleri, yapay sinir ağları, NARX, finans

**2022, xxii + 264 sayfa.**

## ABSTRACT

PhD Thesis

PREDICTION OF MUTUAL FUND CLOSING PRICE (NET ASSET VALUE) AND  
PERFORMANCE USING PORTFOLIO DISTRIBUTION

**Ümit YILMAZ**

Bursa Uludağ University  
Graduate School of Natural and Applied Sciences  
Department of Industrial Engineering

**Supervisor:** Assoc. Prof. Dr. Âli Yurdun ORBAK

Mutual funds are one of the important financial investment types that are professionally managed, diversify the investment by investing in various investment instruments by bringing together the money of the investors and thus spreading the risk to the base. In recent years, the number of mutual funds has been increasing more and more. This fact indicates that selecting specific mutual funds requires significant investor effort in collecting and analyzing information about funds operating in the same investment universe.

Accurate prediction of the closing prices of mutual funds has become an increasingly important issue for investors. Mutual fund investors will be significantly supported by the development of models that accurately predict the future performances of mutual funds. Using these models will facilitate the selection of suitable mutual funds for investors who want to invest in the medium and long term.

The aim of this thesis, using Artificial Neural Networks and Nonlinear Autoregressive Network With Exogenous Inputs (NARX), is to predict the closing price of a mutual fund with the help of fund portfolio distribution and values of performance evaluation methods. The analysis made in the study will provide a helpful perspective to investors and help investors make better decisions about mutual funds. This way, the investors' returns will increase, and the effort they spend on fund selection will decrease.

**Key words:** Mutual fund, portfolio distribution, performance evaluation methods, artificial neural network, NARX, finance

**2022, xxii + 264 pages.**

## TEŐEKKÜR

Doktora tez alıőmam sűresince bana hep inanan, destek olan ve yűn veren kıymetli danıőmanım Do. Dr. li Yurdun Orbak'a, deęerli gűrűőleriyle bana yardımcı olan doktora tez izleme komitesi űyeleri Prof. Dr. Ahmet Emir Dirik ve Do. Dr. Aslı Aksoy'a ve tez savunma sınavımda yer alan Do. Dr. Ayta Yıldız ve Dr. Őęr. űyesi İlkűn Orbak'a teőekkűrlerimi sunarım.

Doktora űęrenimimin ders aőamasında akademik geliőimime bűyűk katkı saęlayan Bursa Uludaę űniversitesi Endűstri Műhendislięi Bűlűmű akademisyenlerine teőekkűrlerimi sunarım. Ayrıca merhum Prof. Dr. Hűseyin Cenk Őzmutlu'yu rahmet ve minnetle anıyorum.

Hayatımın her aőamasında beni sűrekli destekleyen ve her zaman yanımda olan eőim Őzlem Akdoęan Yılmaz'a, kızlarım Azra Sare Yılmaz ve Alya Yaęmur Yılmaz'a, annem Nebibe Yılmaz'a, babam Sabahattin Yılmaz'a ve kardeőim Levent Yılmaz'a teőekkűrlerimi sunarım.

űmit YILMAZ  
30/06/2022

## İÇİNDEKİLER

	<b>Sayfa</b>
ÖZET.....	i
ABSTRACT.....	ii
TEŞEKKÜR.....	iii
SİMGELER ve KISALTMALAR DİZİNİ.....	vi
ŞEKİLLER DİZİNİ.....	vii
ÇİZELGELER DİZİNİ.....	xvii
1. GİRİŞ.....	1
2. KURAMSAL TEMELLER ve KAYNAK ARAŞTIRMASI.....	5
2.1. Yatırım Fonları.....	5
2.1.1. Yatırım fonu kavramı.....	5
2.1.2. Yatırım fonlarının avantajları ve dezavantajları.....	8
2.1.3. Yatırım fonlarının işletilmesi.....	11
2.1.4. Yatırım fonu organizasyonu.....	13
2.1.5. Yatırım fonlarının yatırım hedefine göre sınıflandırılması.....	15
2.1.6. Yatırım fonlarının idari politikaya göre sınıflandırılması.....	18
2.1.7. Yatırım fonları risk faktörleri.....	19
2.2. Portföy Yönetimi.....	22
2.2.1. Portföy ve portföy yönetimi kavramı.....	22
2.2.2. Portföy yöneticisi kavramı.....	23
2.2.3. Portföy yönetimi süreçleri.....	25
2.3. Yatırım Fonu Kapanış Fiyatının Tahminine İlişkin Önceki Araştırmalar.....	43
3. MATERYAL ve YÖNTEM.....	50
3.1. Materyal.....	50
3.2. Yöntem.....	52
3.2.1. Yapay sinir ağları.....	56
3.2.2. Doğrusal olmayan dıřsal girdili otoregresif ağ (NARX).....	74
4. BULGULAR.....	77
4.1. Yatırım Fonu Kapanış Fiyatının Fon Portföy Dağılımından Faydalanılarak Tahmin Edilmesi.....	78
4.1.1. Yatırım fonu kapanış fiyatının fon portföy dağılımından faydalanılarak tahmin edilmesi için YSA model mimarilerinin geliştirilmesi.....	78
4.1.2. Yatırım fonu kapanış fiyatının fon portföy dağılımından faydalanılarak tahmin edilmesi için NARX model mimarilerinin geliştirilmesi.....	122
4.1.3. Yatırım fonu kapanış fiyatının fon portföy dağılımından faydalanılarak tahmin edilmesi için geliştirilen modellerin yeni tarihli veriler ile ek testlere tabi tutulması.....	148
4.2. Yatırım Fonu Kapanış Fiyatının Performans Değerlendirme Yöntemleri Değerlerinden Faydalanılarak Tahmin Edilmesi.....	155
4.2.1. Yatırım fonu kapanış fiyatının performans değerlendirme yöntemleri değerlerinden faydalanılarak tahmin edilmesi için YSA model mimarilerinin geliştirilmesi.....	156
4.2.2. Yatırım fonu kapanış fiyatının performans değerlendirme yöntemleri değerlerinden faydalanılarak tahmin edilmesi için NARX model mimarilerinin geliştirilmesi.....	196

4.2.3. Performans deęerlendirme yntemleri deęerleri ile yatırım fonu kapanıř fiyatının tahmin edilmesi iin geliřtirilen modellerin yeni tarihli veriler ile ek testlere tabi tutulması.....	223
5. TARTIřMA ve SONU.....	230
KAYNAKLAR.....	236
EKLER.....	251
ZGEMİř.....	263

## SİMGELER ve KISALTMALAR DİZİNİ

### Simgeler

### Açıklama

gamk	Etkin Parametre Sayısı
R	Coefficient of Correlation (Korelasyon Katsayısı)
R <sup>2</sup>	Coefficient of Determination (Belirlilik Katsayısı)
ssX	Kareler Toplamı Parametresi

### Kısaltmalar

### Açıklama

BR	Bayesian Regularization (Bayes Düzenlenmesi) Eğitim Algoritması
DBP	Deniz Portföy Birinci Değişken Fon
doğ. hatası	Doğrulama Hatası
DSA	Dolphin Swarm Algorithm (Yunus Sürüsü Algoritması)
ELM	Extreme Learning Machine (Aşırı Öğrenme Makinesi)
FLANN	Functional Link Artificial Neural Network (Fonksiyonel Bağlantılı Yapay Sinir Ağları)
GRU	Gated Recurrent Unit (Geçitlendirilmiş Özyinelemeli Birimler)
HPO	HSBC Portföy Çoklu Varlık Birinci Değişken Fon
IST	İstanbul Portföy Kısa Vadeli Borçlanma Araçları Fonu
LM	Levenberg-Marquardt Eğitim Algoritması
LSTM	Long Short Term Memory (Uzun Kısa Süreli Bellek)
MAE	Mean Absolute Error (Ortalama Mutlak Hata)
MAPE	Mean Absolute Percentage Error (Ortalama Mutlak Yüzde Hatası)
MLANN	Multi Layer Artificial Neural Network (Çok Katmanlı Yapay Sinir Ağları)
MLP	Multi Layer Perceptron (Çok Katmanlı Algılayıcı)
MSE	Mean Squared Error (Ortalama Karesel Hata)
NARX	Nonlinear Autoregressive Network with Exogenous Inputs (Doğrusal Olmayan Dışsal Girdili Otoregresif Ağ)
RBF	Radial Basis Function (Radyal Temel Fonksiyon)
RMSE	Root Mean Squared Error (Ortalama Hata Kare Kökü)
SCG	Scaled Conjugate Gradient (Ölçeklenmiş Konjüge Gradyan) Eğitim Algoritması
SSE	Sum of Squared Errors (Hata Kareler Toplamı)
TEFAS	Türkiye Elektronik Fon Alım Satım Platformu
TE3	TEB Portföy Mutlak Getiri Hedefli Değişken Fon
YSA	Yapay Sinir Ağları
ZGH	Zaman Gecikme Hattı



## ŞEKİLLER DİZİNİ

	<b>Sayfa</b>
Şekil 2.1.	Yatırım sürecindeki ana oyuncular ve aralarındaki etkileşimler... 6
Şekil 2.2.	Ekonomide finansal kaynakların tahsisi ..... 11
Şekil 2.3.	Fon süreç akışı ..... 12
Şekil 2.4.	Tipik bir yatırım fonu kompleksi görüntüleri..... 15
Şekil 2.5.	Portföy yönetimi süreci..... 25
Şekil 2.6.	Çeşitlendirme yoluyla risk azaltma..... 31
Şekil 2.7.	Çince risk sembolleri..... 32
Şekil 2.8.	Portföylerin beklenen değerleri ve riskleri..... 32
Şekil 3.1.	Yapay zekâ, makine öğrenmesi, sinir ağları ve derin öğrenme arasındaki ilişki..... 52
Şekil 3.2.	Makine öğrenmesi çalışma modeli..... 53
Şekil 3.3.	Bir biyolojik nöronun temsili gösterimi..... 57
Şekil 3.4.	Bir yapay nöronun temsili..... 57
Şekil 3.5.	YSA modeli oluşturma akış şeması..... 62
Şekil 3.6.	Sinir ağının çalışma prensibi..... 67
Şekil 3.7.	İleri beslemeli yapay sinir ağı ..... 73
Şekil 3.8.	NARX tasarımı A) Seri Paralel mimari B) Paralel mimari..... 76
Şekil 4.1.	Yatırım fonu kapanış fiyatının tahmin edilmesi için gerçekleştirilen işlem adımları..... 77
Şekil 4.2.	Yatırım fonu kapanış fiyatının fon portföy dağılımından faydalanılarak tahmin edilmesi için geliştirilen tek gizli katmanlı YSA model mimarisi..... 80
Şekil 4.3.	Fon portföy dağılımı ile DBP'nin kapanış fiyatının tahmini için geliştirilen her bir tek gizli katmanlı YSA model mimarisi için gerçekleştirilen test iterasyonları sonucunda elde edilen en iyi MSE değerleri..... 84
Şekil 4.4.	Fon portföy dağılımı ile DBP'nin kapanış fiyatının tahmini için geliştirilen her bir tek gizli katmanlı YSA model mimarisi için gerçekleştirilen test iterasyonları sonucunda elde edilen en iyi MAPE değerleri..... 84
Şekil 4.5.	Fon portföy dağılımı ile DBP'nin kapanış fiyatının tahmini için geliştirilen her bir tek gizli katmanlı YSA model mimarisi için gerçekleştirilen test iterasyonları sonucunda elde edilen en iyi R değerleri..... 85
Şekil 4.6.	Fon portföy dağılımı ile DBP'nin kapanış fiyatının tahmini için geliştirilen tek gizli katmanlı YSA model mimarisi (eğitim algoritması: BR, model: 49-10-1)..... 87
Şekil 4.7.	Fon portföy dağılımı ile DBP'nin kapanış fiyatının tahmin edilmesi için geliştirilen tek gizli katmanlı YSA'nın MSE Performansı (eğitim algoritması: BR, model: 49-10-1)..... 87
Şekil 4.8.	Fon portföy dağılımı ile DBP'nin kapanış fiyatının tahmin edilmesi için geliştirilen tek gizli katmanlı YSA'nın eğitim durumu (eğitim algoritması: BR, model: 49-10-1)..... 89

Şekil 4.9.	Fon portföy dağılımı ile DBP'nin kapanış fiyatının tahmin edilmesi için geliştirilen tek gizli katmanlı YSA'nın hata histogramı (eğitim algoritması: BR, model: 49-10-1).....	90
Şekil 4.10	Fon portföy dağılımı ile DBP'nin kapanış fiyatının tahmin edilmesi için geliştirilen tek gizli katmanlı YSA'nın regresyon grafikleri (eğitim algoritması: BR, model: 49-10-1).....	91
Şekil 4.11.	Fon portföy dağılımı ile IST'nin kapanış fiyatının tahmini için geliştirilen her bir tek gizli katmanlı YSA model mimarisi için gerçekleştirilen test iterasyonları sonucunda elde edilen en iyi MSE değerleri.....	94
Şekil 4.12.	Fon portföy dağılımı ile IST'nin kapanış fiyatının tahmini için geliştirilen her bir tek gizli katmanlı YSA model mimarisi için gerçekleştirilen test iterasyonları sonucunda elde edilen en iyi MAPE değerleri.....	95
Şekil 4.13.	Fon portföy dağılımı ile IST'nin kapanış fiyatının tahmini için geliştirilen her bir tek gizli katmanlı YSA model mimarisi için gerçekleştirilen test iterasyonları sonucunda elde edilen en iyi R değerleri.....	95
Şekil 4.14.	Fon portföy dağılımı ile IST'nin kapanış fiyatının tahmini için geliştirilen tek gizli katmanlı YSA model mimarisi (eğitim algoritması: BR, model: 49-10-1).....	97
Şekil 4.15.	Fon portföy dağılımı ile IST'nin kapanış fiyatının tahmini için geliştirilen tek gizli katmanlı YSA'nın MSE Performansı (eğitim algoritması: BR, model: 49-10-1).....	98
Şekil 4.16.	Fon portföy dağılımı ile IST'nin kapanış fiyatının tahmini için geliştirilen tek gizli katmanlı YSA'nın eğitim durumu (eğitim algoritması: BR, model: 49-10-1).....	99
Şekil 4.17.	Fon portföy dağılımı ile IST'nin kapanış fiyatının tahmini için geliştirilen tek gizli katmanlı YSA'nın hata histogramı (eğitim algoritması: BR, model: 49-10-1).....	100
Şekil 4.18.	Fon portföy dağılımı ile IST'nin kapanış fiyatının tahmini için geliştirilen tek gizli katmanlı YSA'nın regresyon grafikleri (eğitim algoritması: BR, model: 49-10-1).....	101
Şekil 4.19.	Yatırım fonu kapanış fiyatının fon portföy dağılımından faydalanılarak tahmin edilmesi için geliştirilen iki gizli katmanlı YSA model mimarisi.....	102
Şekil 4.20.	Fon portföy dağılımı ile DBP'nin kapanış fiyatının tahmini için geliştirilen her bir iki gizli katmanlı YSA model mimarisi için gerçekleştirilen test iterasyonları sonucunda elde edilen en iyi MSE değerleri.....	105
Şekil 4.21.	Fon portföy dağılımı ile DBP'nin kapanış fiyatının tahmini için geliştirilen her bir iki gizli katmanlı YSA model mimarisi için gerçekleştirilen test iterasyonları sonucunda elde edilen en iyi MAPE değerleri.....	106
Şekil 4.22.	Fon portföy dağılımı ile DBP'nin kapanış fiyatının tahmini için geliştirilen her bir iki gizli katmanlı YSA model mimarisi için gerçekleştirilen test iterasyonları sonucunda elde edilen en iyi R değerleri.....	106

Şekil 4.23.	Fon portföy dağılımı ile DBP'nin kapanış fiyatının tahmini için geliştirilen iki gizli katmanlı YSA model mimarisi (eğitim algoritması: BR, model: 49-5-10-1).....	108
Şekil 4.24.	Fon portföy dağılımı ile DBP'nin kapanış fiyatının tahmini için geliştirilen iki gizli katmanlı YSA'nın MSE Performansı (eğitim algoritması: BR, model: 49-5-10-1).....	109
Şekil 4.25.	Fon portföy dağılımı ile DBP'nin kapanış fiyatının tahmini için geliştirilen iki gizli katmanlı YSA'nın eğitim durumu (eğitim algoritması: BR, model: 49-5-10-1).....	110
Şekil 4.26.	Fon portföy dağılımı ile DBP'nin kapanış fiyatının tahmini için geliştirilen iki gizli katmanlı YSA'nın hata histogramı (eğitim algoritması: BR, model: 49-5-10-1).....	111
Şekil 4.27.	Fon portföy dağılımı ile DBP'nin kapanış fiyatının tahmini için geliştirilen iki gizli katmanlı YSA'nın regresyon grafikleri (eğitim algoritması: BR, model: 49-5-10-1).....	112
Şekil 4.28.	Fon portföy dağılımı ile IST'nin kapanış fiyatının tahmini için geliştirilen her bir iki gizli katmanlı YSA model mimarisi için gerçekleştirilen test iterasyonları sonucunda elde edilen en iyi MSE değerleri.....	116
Şekil 4.29.	Fon portföy dağılımı ile IST'nin kapanış fiyatının tahmini için geliştirilen her bir iki gizli katmanlı YSA model mimarisi için gerçekleştirilen test iterasyonları sonucunda elde edilen en iyi MAPE değerleri.....	116
Şekil 4.30.	Fon portföy dağılımı ile IST'nin kapanış fiyatının tahmini için geliştirilen her bir iki gizli katmanlı YSA model mimarisi için gerçekleştirilen test iterasyonları sonucunda elde edilen en iyi R değerleri.....	117
Şekil 4.31.	Fon portföy dağılımı ile IST'nin kapanış fiyatının tahmini için geliştirilen iki gizli katmanlı YSA model mimarisi (eğitim algoritması: BR, model: 49-6-5-1).....	119
Şekil 4.32.	Fon portföy dağılımı ile IST'nin kapanış fiyatının tahmini için geliştirilen iki gizli katmanlı YSA'nın MSE Performansı (eğitim algoritması: BR, model: 49-6-5-1).....	119
Şekil 4.33.	Fon portföy dağılımı ile IST'nin kapanış fiyatının tahmini için geliştirilen iki gizli katmanlı YSA'nın eğitim durumu (eğitim algoritması: BR, model: 49-6-5-1).....	120
Şekil 4.34.	Fon portföy dağılımı ile IST'nin kapanış fiyatının tahmini için geliştirilen iki gizli katmanlı YSA'nın hata histogramı (eğitim algoritması: BR, model: 49-6-5-1).....	121
Şekil 4.35.	Fon portföy dağılımı ile IST'nin kapanış fiyatının tahmini için geliştirilen iki gizli katmanlı YSA'nın regresyon grafikleri (eğitim algoritması: BR, model: 49-6-5-1).....	122
Şekil 4.36.	Yatırım fonu kapanış fiyatının fon portföy dağılımından faydalanılarak tahmin edilmesi için geliştirilen NARX sinir ağı model mimarisi.....	124
Şekil 4.37.	Fon portföy dağılımı ile DBP'nin kapanış fiyatının tahmini için geliştirilen her bir NARX model mimarisi için gerçekleştirilen test iterasyonları sonucunda elde edilen en iyi MSE değerleri.....	128

Şekil 4.38.	Fon portföy dağılımı ile DBP'nin kapanış fiyatının tahmini için geliştirilen her bir NARX model mimarisi için gerçekleştirilen test iterasyonları sonucunda elde edilen en iyi MAPE değerleri...	128
Şekil 4.39.	Fon portföy dağılımı ile DBP'nin kapanış fiyatının tahmini için geliştirilen her bir NARX model mimarisi için gerçekleştirilen test iterasyonları sonucunda elde edilen en iyi R değerleri.....	129
Şekil 4.40.	Fon portföy dağılımı ile DBP'nin kapanış fiyatının tahmini için geliştirilen NARX model mimarisi (eğitim algoritması: BR, model: 49-(1)-5-1).....	131
Şekil 4.41.	Fon portföy dağılımı ile DBP'nin kapanış fiyatının tahmini için geliştirilen NARX'in MSE Performansı (eğitim algoritması: BR, model: 49-(1)-5-1).....	131
Şekil 4.42.	Fon portföy dağılımı ile DBP'nin kapanış fiyatının tahmini için geliştirilen NARX'in eğitim durumu (eğitim algoritması: BR, model: 49-(1)-5-1).....	132
Şekil 4.43.	Fon portföy dağılımı ile DBP'nin kapanış fiyatının tahmini için geliştirilen NARX'in hata histogramı (eğitim algoritması: BR, model: 49-(1)-5-1).....	133
Şekil 4.44.	Fon portföy dağılımı ile DBP'nin kapanış fiyatının tahmini için geliştirilen NARX'in regresyon grafikleri (eğitim algoritması: BR, model: 49-(1)-5-1).....	134
Şekil 4.45.	Fon portföy dağılımı ile DBP'nin kapanış fiyatının tahmini için geliştirilen NARX'in tahmin sonuçları (eğitim algoritması: BR, model: 49-(1)-5-1).....	135
Şekil 4.46.	Fon portföy dağılımı ile DBP'nin kapanış fiyatının tahmini için geliştirilen NARX'in hata otokorelasyonları (eğitim algoritması: BR, model: 49-(1)-5-1).....	136
Şekil 4.47.	Fon portföy dağılımı ile DBP'nin kapanış fiyatının tahmini için geliştirilen NARX'in girdi-hata çapraz-korelasyonları (eğitim algoritması: BR, model: 49-(1)-5-1).....	136
Şekil 4.48.	Fon portföy dağılımı ile IST'nin kapanış fiyatının tahmini için geliştirilen her bir NARX model mimarisi için gerçekleştirilen test iterasyonları sonucunda elde edilen en iyi MSE değerleri.....	140
Şekil 4.49.	Fon portföy dağılımı ile IST'nin kapanış fiyatının tahmini için geliştirilen her bir NARX model mimarisi için gerçekleştirilen test iterasyonları sonucunda elde edilen en iyi MAPE değerleri...	140
Şekil 4.50.	Fon portföy dağılımı ile IST'nin kapanış fiyatının tahmini için geliştirilen her bir NARX model mimarisi için gerçekleştirilen test iterasyonları sonucunda elde edilen en iyi R değerleri.....	141
Şekil 4.51.	Fon portföy dağılımı ile IST'nin kapanış fiyatının tahmini için geliştirilen NARX model mimarisi (eğitim algoritması: LM, model: 49-(2)-10-1).....	143
Şekil 4.52.	Fon portföy dağılımı ile IST'nin kapanış fiyatının tahmini için geliştirilen NARX'in MSE Performansı (eğitim algoritması: LM, model: 49-(2)-10-1).....	143
Şekil 4.53.	Fon portföy dağılımı ile IST'nin kapanış fiyatının tahmini için geliştirilen NARX'in eğitim durumu (eğitim algoritması: LM, model: 49-(2)-10-1).....	144

Şekil 4.54.	Fon portföy dağılımı ile IST'nin kapanış fiyatının tahmini için geliştirilen NARX'in hata histogramı (eğitim algoritması: LM, model: 49-(2)-10-1).....	145
Şekil 4.55.	Fon portföy dağılımı ile IST'nin kapanış fiyatının tahmini için geliştirilen NARX'in regresyon grafikleri (eğitim algoritması: LM, model: 49-(2)-10-1).....	146
Şekil 4.56.	Fon portföy dağılımı ile IST'nin kapanış fiyatının tahmini için geliştirilen NARX'in tahmin sonuçları (eğitim algoritması: LM, model: 49-(2)-10-1).....	147
Şekil 4.57.	Fon portföy dağılımı ile IST'nin kapanış fiyatının tahmini için geliştirilen NARX'in hata otokorelasyonları (eğitim algoritması: LM, model: 49-(2)-10-1).....	147
Şekil 4.58.	Fon portföy dağılımı ile IST'nin kapanış fiyatının tahmini için geliştirilen NARX'in girdi-hata çapraz-korelasyonları (eğitim algoritması: LM, model: 49-(2)-10-1).....	148
Şekil 4.59.	Fon portföy dağılımı ile DBP'nin kapanış fiyatının tahmini için geliştirilen ve optimal sonuç veren tek gizli katmanlı YSA'nın ek testi sonrasında elde edilen tahmin sonuçları (eğitim algoritması: BR, model: 49-10-1).....	149
Şekil 4.60.	Fon portföy dağılımı ile DBP'nin kapanış fiyatının tahmini için geliştirilen ve optimal sonuç veren iki gizli katmanlı YSA'nın ek testi sonrasında elde edilen tahmin sonuçları (eğitim algoritması: BR, model: 49-5-10-1).....	150
Şekil 4.61.	Fon portföy dağılımı ile DBP'nin kapanış fiyatının tahmini için geliştirilen ve optimal sonuç veren NARX'in ek testi sonrasında elde edilen tahmin sonuçları (eğitim algoritması: BR, model: 49-(1)-5-1).....	150
Şekil 4.62.	Fon portföy dağılımı ile IST'nin kapanış fiyatının tahmini için geliştirilen ve optimal sonuç veren tek gizli katmanlı YSA'nın ek testi sonrasında elde edilen tahmin sonuçları (eğitim algoritması: BR, model: 49-10-1).....	153
Şekil 4.63.	Fon portföy dağılımı ile IST'nin kapanış fiyatının tahmini için geliştirilen ve optimal sonuç veren iki gizli katmanlı YSA'nın ek testi sonrasında elde edilen tahmin sonuçları (eğitim algoritması: BR, model: 49-6-5-1).....	153
Şekil 4.64.	Fon portföy dağılımı ile IST'nin kapanış fiyatının tahmini için geliştirilen ve optimal sonuç veren NARX'in ek testi sonrasında elde edilen tahmin sonuçları (eğitim algoritması: LM, model: 49-(2)-10-1).....	154
Şekil 4.65.	Yatırım fonu kapanış fiyatının performans değerlendirme yöntemleri değerlerinden faydalanılarak tahmin edilmesi için geliştirilen tek gizli katmanlı YSA model mimarisi.....	158
Şekil 4.66.	Performans değerlendirme yöntemleri değerleri ile DBP'nin kapanış fiyatının tahmini için geliştirilen her bir tek gizli katmanlı YSA model mimarisi için gerçekleştirilen test iterasyonları sonucunda elde edilen en iyi MSE değerleri.....	161

Şekil 4.67.	Performans değerlendirme yöntemleri değerleri ile DBP'nin kapanış fiyatının tahmini için geliştirilen her bir tek gizli katmanlı YSA model mimarisi için gerçekleştirilen test iterasyonları sonucunda elde edilen en iyi MAPE değerleri.....	162
Şekil 4.68.	Performans değerlendirme yöntemleri değerleri ile DBP'nin kapanış fiyatının tahmini için geliştirilen her bir tek gizli katmanlı YSA model mimarisi için gerçekleştirilen test iterasyonları sonucunda elde edilen en iyi R değerleri.....	162
Şekil 4.69.	Performans değerlendirme yöntemleri değerleri ile DBP'nin kapanış fiyatının tahmini için geliştirilen tek gizli katmanlı YSA model mimarisi (eğitim algoritması: BR, model: 6-7-1).....	164
Şekil 4.70.	Performans değerlendirme yöntemleri değerleri ile DBP'nin kapanış fiyatının tahmini için geliştirilen tek gizli katmanlı YSA'nın MSE Performansı (eğitim algoritması: BR, model: 6-7-1).....	165
Şekil 4.71.	Performans değerlendirme yöntemleri değerleri ile DBP'nin kapanış fiyatının tahmini için geliştirilen tek gizli katmanlı YSA'nın eğitim durumu (eğitim algoritması: BR, model: 6-7-1)..	165
Şekil 4.72.	Performans değerlendirme yöntemleri değerleri ile DBP'nin kapanış fiyatının tahmini için geliştirilen tek gizli katmanlı YSA'nın hata histogramı (eğitim algoritması: BR, model: 6-7-1).	166
Şekil 4.73.	Performans değerlendirme yöntemleri değerleri ile DBP'nin kapanış fiyatının tahmini için geliştirilen tek gizli katmanlı YSA'nın regresyon grafikleri (eğitim algoritması: BR, model: 6-7-1).....	167
Şekil 4.74.	Performans değerlendirme yöntemleri değerleri ile IST'nin kapanış fiyatının tahmini için geliştirilen her bir tek gizli katmanlı YSA model mimarisi için gerçekleştirilen test iterasyonları sonucunda elde edilen en iyi MSE değerleri.....	171
Şekil 4.75.	Performans değerlendirme yöntemleri değerleri ile IST'nin kapanış fiyatının tahmini için geliştirilen her bir tek gizli katmanlı YSA model mimarisi için gerçekleştirilen test iterasyonları sonucunda elde edilen en iyi MAPE değerleri.....	171
Şekil 4.76.	Performans değerlendirme yöntemleri değerleri ile IST'nin kapanış fiyatının tahmini için geliştirilen her bir tek gizli katmanlı YSA model mimarisi için gerçekleştirilen test iterasyonları sonucunda elde edilen en iyi R değerleri.....	172
Şekil 4.77.	Performans değerlendirme yöntemleri değerleri ile IST'nin kapanış fiyatının tahmini için geliştirilen tek gizli katmanlı YSA model mimarisi (eğitim algoritması: LM, model: 6-10-1).....	174
Şekil 4.78.	Performans değerlendirme yöntemleri değerleri ile IST'nin kapanış fiyatının tahmini için geliştirilen tek gizli katmanlı YSA'nın MSE performansı (eğitim algoritması: BR, model: 6-10-1).....	174
Şekil 4.79.	Performans değerlendirme yöntemleri değerleri ile IST'nin kapanış fiyatının tahmini için geliştirilen tek gizli katmanlı YSA'nın eğitim durumu (eğitim algoritması: BR, model: 6-10-1).....	175

Şekil 4.80.	Performans değerlendirme yöntemleri değerleri ile IST'nin kapanış fiyatının tahmini için geliştirilen tek gizli katmanlı YSA'nın hata histogramı (eğitim algoritması: BR, model: 6-10-1).....	176
Şekil 4.81.	Performans değerlendirme yöntemleri değerleri ile IST'nin kapanış fiyatının tahmini için geliştirilen tek gizli katmanlı YSA'nın regresyon grafikleri (eğitim algoritması: BR, model: 6-10-1).....	177
Şekil 4.82.	Yatırım fonu kapanış fiyatının performans değerlendirme yöntemleri değerlerinden faydalanılarak tahmin edilmesi için geliştirilen iki gizli katmanlı YSA model mimarisi.....	178
Şekil 4.83.	Performans değerlendirme yöntemleri değerleri ile DBP'nin kapanış fiyatının tahmini için geliştirilen her bir iki gizli katmanlı YSA model mimarisi için gerçekleştirilen test iterasyonları sonucunda elde edilen en iyi MSE değerleri.....	181
Şekil 4.84.	Performans değerlendirme yöntemleri değerleri ile DBP'nin kapanış fiyatının tahmini için geliştirilen her bir iki gizli katmanlı YSA model mimarisi için gerçekleştirilen test iterasyonları sonucunda elde edilen en iyi MAPE değerleri.....	182
Şekil 4.85.	Performans değerlendirme yöntemleri değerleri ile DBP'nin kapanış fiyatının tahmini için geliştirilen her bir iki gizli katmanlı YSA model mimarisi için gerçekleştirilen test iterasyonları sonucunda elde edilen en iyi R değerleri.....	182
Şekil 4.86.	DBP'nin performans değerlendirme yöntemleri değerleri ile kapanış fiyatının tahminine ilişkin iki gizli katmanlı YSA model mimarisi (eğitim algoritması: LM, model: 6-8-9-1).....	184
Şekil 4.87.	Performans değerlendirme yöntemleri değerleri ile DBP'nin kapanış fiyatının tahmini için geliştirilen iki gizli katmanlı YSA'nın MSE Performansı (eğitim algoritması: LM, model: 6-8-9-1).....	185
Şekil 4.88.	Performans değerlendirme yöntemleri değerleri ile DBP'nin kapanış fiyatının tahmini için geliştirilen iki gizli katmanlı YSA'nın eğitim durumu (eğitim algoritması: LM, model: 6-8-9-1).....	185
Şekil 4.89.	Performans değerlendirme yöntemleri değerleri ile DBP'nin kapanış fiyatının tahmini için geliştirilen iki gizli katmanlı YSA'nın hata histogramı (eğitim algoritması: LM, model: 6-8-9-1).....	186
Şekil 4.90.	Performans değerlendirme yöntemleri değerleri ile DBP'nin kapanış fiyatının tahmini için geliştirilen iki gizli katmanlı YSA'nın regresyon grafikleri (eğitim algoritması: LM, model: 6-8-9-1).....	187
Şekil 4.91.	Performans değerlendirme yöntemleri değerleri ile IST'nin kapanış fiyatının tahmini için geliştirilen her bir iki gizli katmanlı YSA model mimarisi için gerçekleştirilen test iterasyonları sonucunda elde edilen en iyi MSE değerleri.....	190

Şekil 4.92.	Performans değerlendirme yöntemleri değerleri ile IST'nin kapanış fiyatının tahmini için geliştirilen her bir iki gizli katmanlı YSA model mimarisi için gerçekleştirilen test iterasyonları sonucunda elde edilen en iyi MAPE değerleri.....	191
Şekil 4.93.	Performans değerlendirme yöntemleri değerleri ile IST'nin kapanış fiyatının tahmini için geliştirilen her bir iki gizli katmanlı YSA model mimarisi için gerçekleştirilen test iterasyonları sonucunda elde edilen en iyi R değerleri.....	191
Şekil 4.94.	Performans değerlendirme yöntemleri değerleri ile IST'nin kapanış fiyatının tahmini için geliştirilen iki gizli katmanlı YSA model mimarisi (eğitim algoritması: LM, model: 6-9-9-1).....	193
Şekil 4.95.	Performans değerlendirme yöntemleri değerleri ile IST'nin kapanış fiyatının tahmini için geliştirilen iki gizli katmanlı YSA'nın MSE performansı (eğitim algoritması: LM, model: 6-9-9-1).....	194
Şekil 4.96.	Performans değerlendirme yöntemleri değerleri ile IST'nin kapanış fiyatının tahmini için geliştirilen iki gizli katmanlı YSA'nın eğitim durumu (eğitim algoritması: LM, model: 6-9-9-1).....	194
Şekil 4.97.	Performans değerlendirme yöntemleri değerleri ile IST'nin kapanış fiyatının tahminine ilişkin iki gizli katmanlı YSA'nın hata histogramı (eğitim algoritması: LM, model: 6-9-9-1).....	195
Şekil 4.98.	Performans değerlendirme yöntemleri değerleri ile IST'nin kapanış fiyatının tahminine ilişkin iki gizli katmanlı YSA'nın regresyon grafikleri (eğitim algoritması: LM, model: 6-9-9-1)....	196
Şekil 4.99.	Yatırım fonu kapanış fiyatının performans değerlendirme yöntemleri değerlerinden faydalanılarak tahmin edilmesi için geliştirilen NARX sinir ağı model mimarisi.....	198
Şekil 4.100.	Performans değerlendirme yöntemleri değerleri ile DBP'nin kapanış fiyatının tahmini için geliştirilen her bir NARX model mimarisi için gerçekleştirilen test iterasyonları sonucunda elde edilen en iyi MSE değerleri.....	202
Şekil 4.101.	Performans değerlendirme yöntemleri değerleri ile DBP'nin kapanış fiyatının tahmini için geliştirilen her bir NARX model mimarisi için gerçekleştirilen test iterasyonları sonucunda elde edilen en iyi MAPE değerleri.....	202
Şekil 4.102.	Performans değerlendirme yöntemleri değerleri ile DBP'nin kapanış fiyatının tahmini için geliştirilen her bir NARX model mimarisi için gerçekleştirilen test iterasyonları sonucunda elde edilen en iyi R değerleri.....	203
Şekil 4.103.	Performans değerlendirme yöntemleri değerleri ile DBP'nin kapanış fiyatının tahmini için geliştirilen NARX model mimarisi (eğitim algoritması: BR, model: 6-(1)-9-1).....	205
Şekil 4.104.	Performans değerlendirme yöntemleri değerleri ile DBP'nin kapanış fiyatının tahmini için geliştirilen NARX'in MSE performansı (eğitim algoritması: BR, model: 6-(1)-9-1).....	205



Şekil 4.105.	Performans değerlendirme yöntemleri değerleri ile DBP'nin kapanış fiyatının tahmini için geliştirilen NARX'in eğitim durumu (eğitim algoritması: BR, model: 6-(1)-9-1).....	206
Şekil 4.106.	Performans değerlendirme yöntemleri değerleri ile DBP'nin kapanış fiyatının tahmini için geliştirilen NARX'in hata histogramı (eğitim algoritması: BR, model: 6-(1)-9-1).....	207
Şekil 4.107.	Performans değerlendirme yöntemleri değerleri ile DBP'nin kapanış fiyatının tahmini için geliştirilen NARX'in regresyon grafikleri (eğitim algoritması: BR, model: 6-(1)-9-1).....	208
Şekil 4.108.	Performans değerlendirme yöntemleri değerleri ile DBP'nin kapanış fiyatının tahmini için geliştirilen NARX'in tahmin sonuçları (eğitim algoritması: BR, model: 6-(1)-9-1).....	209
Şekil 4.109.	Performans değerlendirme yöntemleri değerleri ile DBP'nin kapanış fiyatının tahmini için geliştirilen NARX'in hata otokorelasyonları (eğitim algoritması: BR, model: 6-(1)-9-1).....	210
Şekil 4.110.	Performans değerlendirme yöntemleri değerleri ile DBP'nin kapanış fiyatının tahmini için geliştirilen NARX'in girdi-hata çapraz-korelasyonları (eğitim algoritması: BR, model: 6-(1)-9-1)	210
Şekil 4.111.	Performans değerlendirme yöntemleri değerleri ile IST'nin kapanış fiyatının tahmini için geliştirilen her bir NARX model mimarisi için gerçekleştirilen test iterasyonları sonucunda elde edilen en iyi MSE değerleri.....	214
Şekil 4.112.	Performans değerlendirme yöntemleri değerleri ile IST'nin kapanış fiyatının tahmini için geliştirilen her bir NARX model mimarisi için gerçekleştirilen test iterasyonları sonucunda elde edilen en iyi MAPE değerleri.....	214
Şekil 4.113.	Performans değerlendirme yöntemleri değerleri ile IST'nin kapanış fiyatının tahmini için geliştirilen her bir NARX model mimarisi için gerçekleştirilen test iterasyonları sonucunda elde edilen en iyi R değerleri.....	215
Şekil 4.114.	Performans değerlendirme yöntemleri değerleri ile IST'nin kapanış fiyatının tahmini için geliştirilen NARX model mimarisi (eğitim algoritması: LM, model: 6-(3)-9-1).....	217
Şekil 4.115.	Performans değerlendirme yöntemleri değerleri ile IST'nin kapanış fiyatının tahmini için geliştirilen NARX'in MSE Performansı (eğitim algoritması: LM, model: 6-(3)-9-1).....	217
Şekil 4.116.	Performans değerlendirme yöntemleri değerleri ile IST'nin kapanış fiyatının tahmini için geliştirilen NARX'in eğitim durumu (eğitim algoritması: LM, model: 6-(3)-9-1).....	218
Şekil 4.117.	Performans değerlendirme yöntemleri değerleri ile IST'nin kapanış fiyatının tahmini için geliştirilen NARX'in hata histogramı (eğitim algoritması: LM, model: 6-(3)-9-1).....	219
Şekil 4.118.	Performans değerlendirme yöntemleri değerleri ile IST'nin kapanış fiyatının tahmini için geliştirilen NARX'in regresyon grafikleri (eğitim algoritması: LM, model: 6-(3)-9-1).....	220
Şekil 4.119.	Performans değerlendirme yöntemleri değerleri ile IST'nin kapanış fiyatının tahmini için geliştirilen NARX'in tahmin sonuçları (eğitim algoritması: LM, model: 6-(3)-9-1).....	221

Şekil 4.120.	Performans değerlendirme yöntemleri değerleri ile IST'nin kapanış fiyatının tahmini için geliştirilen NARX'in hata otokorelasyonları (eğitim algoritması: LM, model: 6-(3)-9-1).....	222
Şekil 4.121.	Performans değerlendirme yöntemleri değerleri ile IST'nin kapanış fiyatının tahmini için geliştirilen NARX'in girdi-hata çapraz-korelasyonları (eğitim algoritması: LM, model: 6-(3)-9-1).....	222
Şekil 4.122.	Performans değerlendirme yöntemleri değerleri ile DBP'nin kapanış fiyatının tahmini için geliştirilen ve optimal sonuç veren tek gizli katmanlı YSA'nın ek testi sonrasında elde edilen tahmin sonuçları (eğitim algoritması: BR, model: 6-7-1).....	224
Şekil 4.123.	Performans değerlendirme yöntemleri değerleri ile DBP'nin kapanış fiyatının tahmini için geliştirilen ve optimal sonuç veren iki gizli katmanlı YSA'nın ek testi sonrasında elde edilen tahmin sonuçları (eğitim algoritması: LM, model: 6-8-9-1).....	224
Şekil 4.124.	Performans değerlendirme yöntemleri değerleri ile DBP'nin kapanış fiyatının tahmini için geliştirilen ve optimal sonuç veren NARX'in ek testi sonrasında elde edilen tahmin sonuçları (eğitim algoritması: BR, model: 6-(1)-9-1).....	225
Şekil 4.125.	Performans değerlendirme yöntemleri değerleri ile IST'nin kapanış fiyatının tahmini için geliştirilen ve optimal sonuç veren tek gizli katmanlı YSA'nın ek testi sonrasında elde edilen tahmin sonuçları (eğitim algoritması: BR, model: 6-10-1).....	227
Şekil 4.126.	Performans değerlendirme yöntemleri değerleri ile IST'nin kapanış fiyatının tahmini için geliştirilen ve optimal sonuç veren iki gizli katmanlı YSA'nın ek testi sonrasında elde edilen tahmin sonuçları (eğitim algoritması: LM, model: 6-9-9-1).....	227
Şekil 4.127.	Performans değerlendirme yöntemleri değerleri ile IST'nin kapanış fiyatının tahmini için geliştirilen ve optimal sonuç veren NARX'in ek testi sonrasında elde edilen tahmin sonuçları (eğitim algoritması: LM, model: 6-(3)-9-1).....	228

## ÇİZELGELER DİZİNİ

	<b>Sayfa</b>
Çizelge 3.1. 2017-2021/6 yılları arasında en yüksek işlem hacmine sahip ilk 10 fon tipi.....	52
Çizelge 4.1. YSA algoritmasının tasarım parametreleri.....	79
Çizelge 4.2. DBP'nin fon portföy dağılımının tek gizli katmanlı YSA ile eğitimi sonucu elde edilen kapanış fiyatı tahminine ilişkin performans ölçüt değerleri.....	81
Çizelge 4.3. DBP'nin fon portföy dağılımının tek gizli katmanlı YSA ile doğrulanması sonucu elde edilen kapanış fiyatı tahminine ilişkin performans ölçüt değerleri.....	82
Çizelge 4.4. DBP'nin fon portföy dağılımının tek gizli katmanlı YSA ile test edilmesi sonucu elde edilen kapanış fiyatı tahminine ilişkin performans ölçüt değerleri.....	83
Çizelge 4.5. DBP'nin fon portföy dağılımının tek gizli katmanlı YSA ile eğitimi sonucu elde edilen kapanış fiyatı tahminine ilişkin performans ölçüt değerleri (model: 49-10-1).....	85
Çizelge 4.6. DBP'nin fon portföy dağılımının tek gizli katmanlı YSA ile doğrulanması sonucu elde edilen kapanış fiyatı tahminine ilişkin performans ölçüt değerleri (model: 49-10-1).....	86
Çizelge 4.7. DBP'nin fon portföy dağılımının tek gizli katmanlı YSA ile test edilmesi sonucu elde edilen kapanış fiyatı tahminine ilişkin performans ölçüt değerleri (model: 49-10-1).....	86
Çizelge 4.8. IST'nin fon portföy dağılımının tek gizli katmanlı YSA ile eğitimi sonucu elde edilen kapanış fiyatı tahminine ilişkin performans ölçüt değerleri.....	92
Çizelge 4.9. IST'nin fon portföy dağılımının tek gizli katmanlı YSA ile doğrulanması sonucu elde edilen kapanış fiyatı tahminine ilişkin performans ölçüt değerleri.....	93
Çizelge 4.10. IST'nin fon portföy dağılımının tek gizli katmanlı YSA ile test edilmesi sonucu elde edilen kapanış fiyatı tahminine ilişkin performans ölçüt değerleri.....	94
Çizelge 4.11. IST'nin fon portföy dağılımının tek gizli katmanlı YSA ile eğitimi sonucu elde edilen kapanış fiyatı tahminine ilişkin performans ölçüt değerleri (model: 49-10-1).....	96
Çizelge 4.12. IST'nin fon portföy dağılımının tek gizli katmanlı YSA ile doğrulanması sonucu elde edilen kapanış fiyatı tahminine ilişkin performans ölçüt değerleri (model: 49-10-1).....	96
Çizelge 4.13. IST'nin fon portföy dağılımının tek gizli katmanlı YSA ile test edilmesi sonucu elde edilen kapanış fiyatı tahminine ilişkin performans ölçüt değerleri (model: 49-10-1).....	97
Çizelge 4.14. DBP'nin fon portföy dağılımının iki gizli katmanlı YSA ile eğitimi sonucu elde edilen kapanış fiyatı tahminine ilişkin performans ölçüt değerleri.....	103
Çizelge 4.15. DBP'nin fon portföy dağılımının iki gizli katmanlı YSA ile doğrulanması sonucu elde edilen kapanış fiyatı tahminine ilişkin performans ölçüt değerleri.....	104

Çizelge 4.16.	DBP'nin fon portföy dağılımının iki gizli katmanlı YSA ile test edilmesi sonucu elde edilen kapanış fiyatı tahminine ilişkin performans ölçüt değerleri.....	105
Çizelge 4.17.	DBP'nin fon portföy dağılımının iki gizli katmanlı YSA ile eğitimi sonucu elde edilen kapanış fiyatı tahminine ilişkin performans ölçüt değerleri (model: 49-5-10-1).....	107
Çizelge 4.18.	DBP'nin fon portföy dağılımının iki gizli katmanlı YSA ile doğrulanması sonucu elde edilen kapanış fiyatı tahminine ilişkin performans ölçüt değerleri (model: 49-5-10-1).....	107
Çizelge 4.19.	DBP'nin fon portföy dağılımının iki gizli katmanlı YSA ile test edilmesi sonucu elde edilen kapanış fiyatı tahminine ilişkin performans ölçüt değerleri (model: 49-5-10-1).....	108
Çizelge 4.20.	IST'nin fon portföy dağılımının iki gizli katmanlı YSA ile eğitimi sonucu elde edilen kapanış fiyatı tahminine ilişkin performans ölçüt değerleri.....	113
Çizelge 4.21.	IST'nin fon portföy dağılımının iki gizli katmanlı YSA ile doğrulanması sonucu elde edilen kapanış fiyatı tahminine ilişkin performans ölçüt değerleri.....	114
Çizelge 4.22.	IST'nin fon portföy dağılımının iki gizli katmanlı YSA ile test edilmesi sonucu elde edilen kapanış fiyatı tahminine ilişkin performans ölçüt değerleri.....	115
Çizelge 4.23.	IST'nin fon portföy dağılımının iki gizli katmanlı YSA ile eğitimi sonucu elde edilen kapanış fiyatı tahminine ilişkin performans ölçüt değerleri (model: 49-6-5-1).....	117
Çizelge 4.24.	IST'nin fon portföy dağılımının iki gizli katmanlı YSA ile doğrulanması sonucu elde edilen kapanış fiyatı tahminine ilişkin performans ölçüt değerleri (model: 49-6-5-1).....	118
Çizelge 4.25.	IST'nin fon portföy dağılımının iki gizli katmanlı YSA ile test edilmesi sonucu elde edilen kapanış fiyatı tahminine ilişkin performans ölçüt değerleri (model: 49-6-5-1).....	118
Çizelge 4.26.	NARX algoritmasının tasarım parametreleri.....	123
Çizelge 4.27.	DBP'nin fon portföy dağılımının NARX ile eğitimi sonucu elde edilen kapanış fiyatı tahminine ilişkin performans ölçüt değerleri.....	125
Çizelge 4.28.	DBP'nin fon portföy dağılımının NARX ile doğrulanması sonucu elde edilen kapanış fiyatı tahminine ilişkin performans ölçüt değerleri.....	126
Çizelge 4.29.	DBP'nin fon portföy dağılımının NARX ile test edilmesi sonucu elde edilen kapanış fiyatı tahminine ilişkin performans ölçüt değerleri.....	127
Çizelge 4.30.	DBP'nin fon portföy dağılımının NARX ile eğitimi sonucu elde edilen kapanış fiyatı tahminine ilişkin performans ölçüt değerleri (model: 49-(1)-5-1).....	129
Çizelge 4.31.	DBP'nin fon portföy dağılımının NARX ile doğrulanması sonucu elde edilen kapanış fiyatı tahminine ilişkin performans ölçüt değerleri (model: 49-(1)-5-1).....	130

Çizelge 4.32.	DBP'nin fon portföy dağılımının NARX ile test edilmesi sonucu elde edilen kapanış fiyatı tahminine ilişkin performans ölçüt değerleri (model: 49-(1)-5-1).....	130
Çizelge 4.33.	IST'nin fon portföy dağılımının NARX ile eğitimi sonucu elde edilen kapanış fiyatı tahminine ilişkin performans ölçüt değerleri.....	137
Çizelge 4.34.	IST'nin fon portföy dağılımının NARX ile doğrulanması sonucu elde edilen kapanış fiyatı tahminine ilişkin performans ölçüt değerleri.....	138
Çizelge 4.35.	IST'nin fon portföy dağılımının NARX ile test edilmesi sonucu elde edilen kapanış fiyatı tahminine ilişkin performans ölçüt değerleri.....	139
Çizelge 4.36.	IST'nin fon portföy dağılımının NARX ile eğitimi sonucu elde edilen kapanış fiyatı tahminine ilişkin performans ölçüt değerleri (model: 49-(2)-10-1).....	141
Çizelge 4.37.	IST'nin fon portföy dağılımının NARX ile doğrulanması sonucu elde edilen kapanış fiyatı tahminine ilişkin performans ölçüt değerleri (model: 49-(2)-10-1).....	142
Çizelge 4.38.	IST'nin fon portföy dağılımının NARX ile test edilmesi sonucu elde edilen kapanış fiyatı tahminine ilişkin performans ölçüt değerleri (model: 49-(2)-10-1).....	142
Çizelge 4.39.	DBP'nin kapanış fiyatının fon portföy dağılımından faydalanılarak tahmin edilmesi için geliştirilen ve optimal sonuç veren tek gizli katmanlı YSA, iki gizli katmanlı YSA ve NARX model mimarileri.....	149
Çizelge 4.40.	DBP'nin 125 iş günlük yeni tarihli veri için tek gizli katmanlı YSA, iki gizli katmanlı YSA ve NARX ile ek testlere tabi tutulması sonucu elde edilen kapanış fiyatı tahminlerine ilişkin performans ölçüt değerleri.....	152
Çizelge 4.41.	IST'nin kapanış fiyatının fon portföy dağılımından faydalanılarak tahmin edilmesi için geliştirilen ve optimal sonuç veren tek gizli katmanlı YSA, iki gizli katmanlı YSA ve NARX model mimarileri.....	152
Çizelge 4.42.	IST'nin 125 iş günlük yeni tarihli veri için tek gizli katmanlı YSA, iki gizli katmanlı YSA ve NARX ile ek testlere tabi tutulması sonucu elde edilen kapanış fiyatı tahminlerine ilişkin performans ölçüt değerleri.....	155
Çizelge 4.43.	YSA algoritmasının tasarım parametreleri.....	157
Çizelge 4.44.	DBP'nin performans değerlendirme yöntemleri değerlerinin tek gizli katmanlı YSA ile eğitimi sonucu elde edilen kapanış fiyatı tahminine ilişkin performans ölçüt değerleri.....	159
Çizelge 4.45.	DBP'nin performans değerlendirme yöntemleri değerlerinin tek gizli katmanlı YSA ile doğrulanması sonucu elde edilen kapanış fiyatı tahminine ilişkin performans ölçüt değerleri.....	160
Çizelge 4.46.	DBP'nin performans değerlendirme yöntemleri değerlerinin tek gizli katmanlı YSA ile test edilmesi sonucu elde edilen kapanış fiyatı tahminine ilişkin performans ölçüt değerleri.....	161

Çizelge 4.47.	DBP'nin performans değerlendirme yöntemleri değerlerinin tek gizli katmanlı YSA ile eğitimi sonucu elde edilen kapanış fiyatı tahminine ilişkin performans ölçüt değerleri (model: 6-7-1).....	163
Çizelge 4.48.	DBP'nin performans değerlendirme yöntemleri değerlerinin tek gizli katmanlı YSA ile doğrulanması sonucu elde edilen kapanış fiyatı tahminine ilişkin performans ölçüt değerleri (model: 6-7-1).....	163
Çizelge 4.49.	DBP'nin performans değerlendirme yöntemleri değerlerinin tek gizli katmanlı YSA ile test edilmesi sonucu elde edilen kapanış fiyatı tahminine ilişkin performans ölçüt değerleri (model: 6-7-1).....	164
Çizelge 4.50.	IST'nin performans değerlendirme yöntemleri değerlerinin tek gizli katmanlı YSA ile eğitimi sonucu elde edilen kapanış fiyatı tahminine ilişkin performans ölçüt değerleri.....	168
Çizelge 4.51.	IST'nin performans değerlendirme yöntemleri değerlerinin tek gizli katmanlı YSA ile doğrulanması sonucu elde edilen kapanış fiyatı tahminine ilişkin performans ölçüt değerleri.....	169
Çizelge 4.52.	IST'nin performans değerlendirme yöntemleri değerlerinin tek gizli katmanlı YSA ile test edilmesi sonucu elde edilen kapanış fiyatı tahminine ilişkin performans ölçüt değerleri.....	170
Çizelge 4.53.	IST'nin performans değerlendirme yöntemleri değerlerinin tek gizli katmanlı YSA ile eğitimi sonucu elde edilen kapanış fiyatı tahminine ilişkin performans ölçüt değerleri (model: 6-10-1)....	172
Çizelge 4.54.	IST'nin performans değerlendirme yöntemleri değerlerinin tek gizli katmanlı YSA ile doğrulanması sonucu elde edilen kapanış fiyatı tahminine ilişkin performans ölçüt değerleri (model: 6-10-1).....	173
Çizelge 4.55.	IST'nin performans değerlendirme yöntemleri değerlerinin tek gizli katmanlı YSA ile test edilmesi sonucu elde edilen kapanış fiyatı tahminine ilişkin performans ölçüt değerleri (model: 6-10-1).....	173
Çizelge 4.56.	DBP'nin performans değerlendirme yöntemleri değerlerinin iki gizli katmanlı YSA ile eğitimi sonucu elde edilen kapanış fiyatı tahminine ilişkin performans ölçüt değerleri.....	179
Çizelge 4.57.	DBP'nin performans değerlendirme yöntemleri değerlerinin iki gizli katmanlı YSA ile doğrulanması sonucu elde edilen kapanış fiyatı tahminine ilişkin performans ölçüt değerleri.....	180
Çizelge 4.58.	DBP'nin performans değerlendirme yöntemleri değerlerinin iki gizli katmanlı YSA ile test edilmesi sonucu elde edilen kapanış fiyatı tahminine ilişkin performans ölçüt değerleri.....	181
Çizelge 4.59.	DBP'nin performans değerlendirme yöntemleri değerlerinin iki gizli katmanlı YSA ile eğitimi sonucu elde edilen kapanış fiyatı tahminine ilişkin performans ölçüt değerleri (model: 6-8-9-1)...	183
Çizelge 4.60.	DBP'nin performans değerlendirme yöntemleri değerlerinin iki gizli katmanlı YSA ile doğrulanması sonucu elde edilen kapanış fiyatı tahminine ilişkin performans ölçüt değerleri (model: 6-8-9-1).....	183

Çizelge 4.61.	DBP'nin performans değerlendirme yöntemleri değerlerinin iki gizli katmanlı YSA ile test edilmesi sonucu elde edilen kapanış fiyatı tahminine ilişkin performans ölçüt değerleri (model: 6-8-9-1).....	184
Çizelge 4.62.	IST'nin performans değerlendirme yöntemleri değerlerinin iki gizli katmanlı YSA ile eğitimi sonucu elde edilen kapanış fiyatı tahminine ilişkin performans ölçüt değerleri.....	188
Çizelge 4.63.	IST'nin performans değerlendirme yöntemleri değerlerinin iki gizli katmanlı YSA ile doğrulanması sonucu elde edilen kapanış fiyatı tahminine ilişkin performans ölçüt değerleri.....	189
Çizelge 4.64.	IST'nin performans değerlendirme yöntemleri değerlerinin iki gizli katmanlı YSA ile test edilmesi sonucu elde edilen kapanış fiyatı tahminine ilişkin performans ölçüt değerleri.....	190
Çizelge 4.65.	IST'nin performans değerlendirme yöntemleri değerlerinin iki gizli katmanlı YSA ile eğitimi sonucu elde edilen kapanış fiyatı tahminine ilişkin performans ölçüt değerleri (model: 6-9-9-1)...	192
Çizelge 4.66.	IST'nin performans değerlendirme yöntemleri değerlerinin iki gizli katmanlı YSA ile doğrulanması sonucu elde edilen kapanış fiyatı tahminine ilişkin performans ölçüt değerleri (model: 6-9-9-1).....	192
Çizelge 4.67.	IST'nin performans değerlendirme yöntemleri değerlerinin iki gizli katmanlı YSA ile test edilmesi sonucu elde edilen kapanış fiyatı tahminine ilişkin performans ölçüt değerleri (model: 6-9-9-1).....	193
Çizelge 4.68.	NARX algoritmasının tasarım parametreleri.....	197
Çizelge 4.69.	DBP'nin performans değerlendirme yöntemleri değerlerinin NARX ile eğitimi sonucu elde edilen kapanış fiyatı tahminine ilişkin performans ölçüt değerleri.....	199
Çizelge 4.70.	DBP'nin performans değerlendirme yöntemleri değerlerinin NARX ile doğrulanması sonucu elde edilen kapanış fiyatı tahminine ilişkin performans ölçüt değerleri.....	200
Çizelge 4.71.	DBP'nin performans değerlendirme yöntemleri değerlerinin NARX ile test edilmesi sonucu elde edilen kapanış fiyatı tahminine ilişkin performans ölçüt değerleri.....	201
Çizelge 4.72.	DBP'nin performans değerlendirme yöntemleri değerlerinin NARX ile eğitimi sonucu elde edilen kapanış fiyatı tahminine ilişkin performans ölçüt değerleri (model: 6-(1)-9-1).....	203
Çizelge 4.73.	DBP'nin performans değerlendirme yöntemleri değerlerinin NARX ile doğrulanması sonucu elde edilen kapanış fiyatı tahminine ilişkin performans ölçüt değerleri (model: 6-(1)-9-1).	204
Çizelge 4.74.	DBP'nin performans değerlendirme yöntemleri değerlerinin NARX ile test edilmesi sonucu elde edilen kapanış fiyatı tahminine ilişkin performans ölçüt değerleri (model: 6-(1)-9-1).	204
Çizelge 4.75.	IST'nin performans değerlendirme yöntemleri değerlerinin NARX ile eğitimi sonucu elde edilen kapanış fiyatı tahminine ilişkin performans ölçüt değerleri.....	211

Çizelge 4.76.	IST'nin performans değerlendirme yöntemleri değerlerinin NARX ile doğrulanması sonucu elde edilen kapanış fiyatı tahminine ilişkin performans ölçüt değerleri.....	212
Çizelge 4.77.	IST'nin performans değerlendirme yöntemleri değerlerinin NARX ile test edilmesi sonucu elde edilen kapanış fiyatı tahminine ilişkin performans ölçüt değerleri.....	213
Çizelge 4.78.	IST'nin performans değerlendirme yöntemleri değerlerinin NARX ile eğitimi sonucu elde edilen kapanış fiyatı tahminine ilişkin performans ölçüt değerleri (model: 6-(3)-9-1).....	215
Çizelge 4.79.	IST'nin performans değerlendirme yöntemleri değerlerinin NARX ile doğrulanması sonucu elde edilen kapanış fiyatı tahminine ilişkin performans ölçüt değerleri (model: 6-(3)-9-1).	216
Çizelge 4.80.	IST'nin performans değerlendirme yöntemleri değerlerinin NARX ile test edilmesi sonucu elde edilen kapanış fiyatı tahminine ilişkin performans ölçüt değerleri (model: 6-(3)-9-1).	216
Çizelge 4.81.	DBP'nin kapanış fiyatının performans değerlendirme yöntemleri değerlerinden faydalanılarak tahmin edilmesi için geliştirilen ve optimal sonuç veren tek gizli katmanlı YSA, iki gizli katmanlı YSA ve NARX model mimarileri.....	223
Çizelge 4.82.	DBP'nin 125 iş günlük yeni tarihli veri için tek gizli katmanlı YSA, iki gizli katmanlı YSA ve NARX ile ek testlere tabi tutulması sonucu elde edilen kapanış fiyatı tahminlerine ilişkin performans ölçüt değerleri.....	226
Çizelge 4.83.	IST'nin kapanış fiyatının performans değerlendirme yöntemleri değerlerinden faydalanılarak tahmin edilmesi için geliştirilen ve optimal sonuç veren tek gizli katmanlı YSA, iki gizli katmanlı YSA ve NARX model mimarileri.....	226
Çizelge 4.84.	IST'nin 125 iş günlük yeni tarihli veri için tek gizli katmanlı YSA, iki gizli katmanlı YSA ve NARX ile ek testlere tabi tutulması sonucu elde edilen kapanış fiyatı tahminlerine ilişkin performans ölçüt değerleri.....	229



## 1. GİRİŞ

Menkul kıymet yatırım fonları, menkul kıymet portföyü oluşturmak amacıyla kurulan mal varlıklarıdır. Menkul kıymet yatırım fonu yöneticileri, tasarruf sahiplerinden (yatırımcı) topladıkları paralar (fon) ile sermaye piyasası araçlarından ve kıymetli madenlerden oluşan portföyleri yönetmektedir. Tasarruf sahipleri ise, fonlar tarafından çıkarılan katılma belgelerini almak suretiyle menkul kıymetlere yatırım yaparak fonun oluşturduğu portföyün gelirinden yararlanma olanağına kavuşmaktadır (Sayılgan, 2019). Menkul kıymet yatırım fonları, yatırımcıların paralarını diğer yatırımcılarla bir araya getiren ve profesyonel olarak yönetilen yatırım türleridir. Çeşitlendirme yapmak için yeterli zamana, uzmanlığa ve tasarruf miktarına sahip olmayan yatırımcılar, tasarruflarını menkul kıymet yatırım fonlarına yatırarak çeşitlilik ve uzman para yönetimi gibi birçok profesyonel hizmetten faydalanabilirler (Sarigül, 2019).

Yatırım fonu tasarım gereği iyi çeşitlendirilmiş bir portföy veya farklı varlıklardan oluşan bir sepettir. Portföy bileşimi, bir yandan yatırım fonlarının getirisini belirleyen en önemli faktörlerden biri iken, diğer yandan da sistemde biriken kaynakların ekonomide hangi alanlara kanalize edildiğini ortaya koyan önemli göstergelerden biridir (Oktayer ve Oktayer, 2007). Portföy bileşimi, yatırımcının paranın nereye ve hangi oranda gittiğini tam olarak bilmesi dolayısıyla analiz için en önemli araçlardan biridir.

Her bir yatırım fonunda gözlemlenen getirilerin neredeyse tamamı portföy varlıkları yardımıyla açıklanabilmektedir (Santos ve Vianna, 2019). Ekonomi için gittikçe önemi artan yatırım fonlarının portföy bileşimi içinde yer alan finansal araçların zaman içinde göstermiş olduğu değişimler fonların getirilerini doğrudan etkilemektedir. Bu durum yatırım fonlarına yatırımda bulunan kişilerin potansiyel getirileri üzerinde önemli bir etki yaratabilmektedir (Kurtaran ve Kurtaran, 2010). Stankevičienė ve Petronienė (2019) tarafından ele alınan çalışma da fonların performansının portföy bileşimine bağlı olduğunu göstermektedir.

Yatırım fonunun getirisi, portföyünde bulundurduğu varlıkların getirisine bağlı olduğundan yatırımcıların fonun türü, bir başka deyişle portföy bileşimi hakkında bilgi sahibi olduktan sonra yatırım yapacakları fonu seçmeleri uygun olacaktır (SPK, 2021).

Fon kategorileri arasında portföy bileşimindeki farklılıklar, fonlar tarafından izlenen farklı yatırım politikalarını yansıtmaktadır (Bouveret ve Ju, 2021). Fon bileşimi, fonun yatırım politikasına ilişkin güvenilir ve temsili bilgiler sağlamaktadır. Bundan dolayı portföy bileşimi yalnızca baştan değil, tüm analiz dönemince bilinmelidir. Ayrıca, portföy için en son verileri almak için bu bilgilerin günlük olarak güncellenmesi gerekmektedir (Le Sourd, 2007).

Piyasadaki yeni bilgiler nedeniyle öngörülemeyen varlık fiyat hareketleri, yatırım yöneticilerini artan getiri umuduyla işlem yapmaya ve portföy bileşimini ayarlamaya zorlamaktadır (Rachmawati vd., 2020). Bir yatırım fonunun aktif yönetimi, fonun menkul kıymet portföyünün bileşimini düzenli olarak ayarlayarak, temsili bir piyasa portföyünden daha iyi bir getiri elde etmeyi amaçlamaktadır (Milan ve Junior, 2015). Bundan dolayı portföy bileşimi nedeniyle fonun net varlık değerinin yüksek bir oynaklığa sahip olması muhtemeldir (Melgar ve Rodriguez Vazquez, 2009).

Finansal zaman serisi verilerinden anlamlı istatistikler çıkarmak ve bunları etkin ve doğru bir şekilde tahmin etmek, finansal veri madenciliğinde gelişmekte olan ve öne çıkan bir araştırma alanıdır. Yatırım fonu yatırımcıları, sahip oldukları fonların fiyatlarında meydana gelen artışlar paralelinde getiri elde etmektedir. Bundan dolayı yatırım fonlarının kapanış fiyatlarının doğru bir şekilde tahmin edilmesi yatırımcılar açısından giderek daha önemli bir konu haline gelmiştir. Sıradan bir insan için, yatırım fonu gibi oldukça değişken bir piyasada meydana gelebilecek dalgalanmayı tahmin etmek zor bir iştir. Dolayısıyla, kapanış fiyatı tahmini kesinlikle finans alanı altında gelişmekte olan bir araştırma alanıdır (Mohanty ve Dash, 2021).

Çalışmanın ilk amacı, makine öğrenmesi algoritmaları kullanarak, fon portföy dağılımı yardımıyla bir yatırım fonunun kapanış fiyatını doğru tahmin etmektir.

Yatırım fonları, kabul edilebilir bir riske katlanarak mümkün olan en iyi getiriye sağlamak amacıyla yatırım yapmak isteyen yatırımcılar için güçlü bir yatırım aracıdır. Yatırımcıların en büyük sorunu, yatırım fonu getirilerine ilişkin yetersiz veri olup, bu da yüksek riskli veya düşük kârlı fonlara yatırım yapılmasına neden olabilir (Promptsook ve Waiyamai, 2021).

Fonun geçmiş performansının gelecekte de aynı performansı vereceği garanti olmasa da fon değerlendirilirken fonun son birkaç yıllık performansının dikkate alınması gerekmektedir. Yatırım fonlarının gelecek performanslarının doğru tahminini sağlayan modellerin geliştirilmesi, yatırım fonu yatırımcılarına büyük destek sağlayacaktır. Bu modellerin kullanımı, orta-uzun vadede yatırım yapmak isteyen yatırımcıların yatırım fonu seçimini kolaylaştıracaktır.

Bir fonun performansını değerlendirmek için çok sayıda ölçüt geliştirilmiştir ve birçok yatırımcı bu ölçütlere büyük önem vermektedir. Ancak, yatırım fonları için değerlendirmeler periyodik olarak yapıldığından sadece tarihsel performansı karşılaştırmak için faydalı olmaktadır. Hızla değişen piyasa koşullarına ayak uydurabilmek için, değerlendirme sistemlerinin piyasa ile eşzamanlı olarak güncellenmesi ve piyasa koşullarına uygun çıktılar vermesi gerekmektedir. Diğer yandan bahsi geçen ölçütler sıklıkla performans değerlendirmeleri için kullanılsa da tek başlarına tahmin edici özelliğe sahip olmadıklarından doğrudan yatırım fonlarının tahmininde kullanılamazlar (Wang vd., 2008). İşte bu noktada çalışmanın ikinci amacı, yatırım fonu kapanış fiyatını, performans değerlendirme yöntemleri değerleriyle tahmin edebilecek bir makine öğrenmesi modeli geliştirebilmektir. Belirtilen amaç doğrultusunda bahsi geçen performans değerlendirme yöntemleriyle elde edilen sonuçlar vasıtasıyla fonun trendinin belirlenmesine odaklanılmıştır.

Makine öğrenmesi algoritmaları, menkul kıymetlerin teknik analizini yapmak, daha doğru tahmin modelleri geliştirmek, piyasayı analiz etmek, belirli durumların menkul kıymetlerin üzerindeki etkisini ölçmek, maksimum kazanç için portföy oluşturmak ve portföyü optimize etmek için yaygın olarak kullanılmaktadır. Yapay Sinir Ağları (YSA) ve derin öğrenme algoritmaları gibi makine öğrenmesi algoritmaları, finans alanında

yaygın olarak uygulanmakta ve kabul gören yöntemler olarak değerlendirilmektedir (Gülyüz ve Özden, 2020).

Çalışmada yapılacak analiz, yatırımcılara yararlı bir bakış açısı sağlayacak, yatırımcıların yatırım fonu hakkında daha iyi kararlar almasına yardımcı olacak ve bu sayede yatırımcıların incelemeye aldıkları fondan elde edecekleri getiriye öngörebilmelerinin önü açılacaktır.

Yapılan literatür çalışması da göz önünde bulundurulduğunda literatürde aynı özelliklere benzer senaryolar mevcut değildir ve dolayısıyla çalışmanın amaçlarını oluşturan bu problemler literatürde açık problemler olup henüz incelenmemiştir. İlk defa bu problemlerin tanımı yapılarak literatürdeki yatırım fonu kapanış fiyatlarının (net aktif değerlerinin) tahmin edilmesi çalışmalarına yenileri eklenecektir.

## **2. KURAMSAL TEMELLER ve KAYNAK ARAŞTIRMASI**

### **2.1. Yatırım Fonları**

Piyasalarda farklı finansal araçlara duyulan ihtiyaç, enflasyon ve faiz oranlarındaki dalgalanmalar, yasal düzenlemelerde yaşanan sürekli değişiklikler, teknolojiye gelişmeler, ekonomik büyümenin hızlanması gibi sebeplerle hızla artmıştır. Finansal araçların çeşitlenmesiyle de piyasaların daha etkin olması beklenmektedir (Yücel, 2018). Bahsi geçen finansal araçlardan biri olan yatırım fonları gün geçtikçe yatırımcıların dikkatini üzerlerine çekmektedir.

#### **2.1.1. Yatırım fonu kavramı**

Yatırım fonları, fon fazlası olanlardan topladıkları tasarruflar ile riskin dağıtılması ilkesine uygun olarak uzman kişilerin güvencesi altında portföy oluşturup gelir elde etmek için faaliyet gösteren sermaye piyasası yatırım şirketleridir. Bunlar, bireysel yatırımcıların tasarruflarını bir araya getirerek bir havuz oluşturmakta ve bunu çeşitli finansal araçlara yatırarak değerlendirmektedir (Sarigül, 2019).

Yatırım fonları, aracı kurumlar ve finansal kurumlar tarafından, halktan katılım belgeleri karşılığı toplanan fonlarla belge sahipleri hesabına oluşturulan ve sermaye ve para piyasası finansal varlıklarını içeren fonlardır. Katılım belgelerinin nominal değeri olmayıp değeri temsil ettikleri fonun herhangi bir andaki pazar değerinin katılım belgesi sayısına bölünmesiyle hesaplanır. Katılım belgeleri yatırımcılar tarafından istenildiği anda fona iade edilerek paraya dönüştürülebilir (Gürsoy, 2007).

Yatırım fonu, birkaç farklı yatırımcıdan para toplayan ve hisse senedi, tahvil veya diğer yatırımlardan oluşan bir portföy satın almak için birleşik varlık havuzunu kullanan finansal bir araçtır. Portföy başarılı olursa ve finansal olarak kazanç sağlarsa, fondaki yatırımcıların her biri bu pozitif getirilerden orantılı bir pay alacaktır. Öte yandan, portföy başarısız olursa, yatırımcılar bir yatırım fonu aracılığıyla birlikte çalışarak ortaya çıkan işlem maliyetlerinin yanı sıra zararları da paylaşmaktadır.

Yeterli kaynağa ve boş zamana sahip yatırımcılar, alternatif bir teknik olarak, kendi yatırım portföylerini basitçe bir araya getirebilirler. Geniş bir hisse senedi veya tahvil koleksiyonu elde etmek için diğer hissedarlarla güçlerini birleştirmeye veya mali danışmanlardan yardım almalarına gerek yoktur. Bununla birlikte, tüm bu işlemleri araştırmak ve hayata geçirmek için zaman ve para harcamaya istekli olmalıdırlar. Yatırım fonları bu iki kaynağın idareli kullanılmasına yardımcı olmaktadır (Birdthistle, 2016).

Profesyonelce yönetilen bir yatırım fonu, bireylerin ve kurumların küçük tutarlardaki paralarını büyük bir yatırım tutarı olarak birleştirmesine olanak tanır. Varlıkların bu şekilde birleştirilmesi, bu bireylerin ve grupların ölçek ekonomisinden faydalanarak düşük aracılık komisyonu ödemelerine ve çeşitlendirme yoluyla risklerini azaltmalarına olanak tanır. Yatırım fonu terimi, hissedar ile fon arasındaki karşılıklı ilişkiyi ifade etmektedir. Fon, fonun net varlık değerine bağlı bir fiyatla yatırımcılara pay satar veya parasını geri isteyenlerin paylarını geri alır. Net varlık değeri, işlem günü sonunda bir fon payının fiyatını ifade etmektedir (Gerber, 2008).

Türk yatırım fonlarına yatırım yapma süreci Şekil 2.1’de özetlenmiştir. Yatırım sürecinde üç ana oyuncu vardır. Yatırım şirketi fonu kurar ve çalıştırmak için fon yöneticisini kullanır. Yatırımcı, yatırım fonunda yatırım birimlerini satın alır (Ber vd., 2007).



**Şekil 2.1.** Yatırım sürecindeki ana oyuncular ve aralarındaki etkileşimler (Ber vd., 2007)

Yatırım fonlarının alım ve satımı fon kurucusunun yanı sıra Türkiye Elektronik Fon Alım Satım Platformuna (TEFAS) üye olan fon dağıtım kuruluşları aracılığıyla da

yapılmaktadır. Türkiye genelinde tüm bankalar ve aracı kurumlar tüm fonları müşterilerine satmakla yükümlüdürler (Fibaportföy, 2021).

Yatırım fonu yatırımının dört temel ilkesi, sektörün başarısının özünü oluşturmaktadır. Bunlar aşağıdaki gibi detaylıca açıklanabilir (Bogle, 2015):

- Geniş çeşitlilik: Yatırım fonu yatırımının ilk ilkesi, menkul kıymetlerin geniş bir şekilde çeşitlendirilmesidir. Sermaye piyasası teorisi, belirli menkul kıymetlerde açıkça verimsiz risk alma gibi görünen şeyleri (sistemik olmayan risk) ortadan kaldırmak için çeşitlendirmenin gerekli olduğunu öne sürmektedir. Çok sayıda finansal araştırma, çoğu bireysel yatırımcının ne yazık ki portföylerini yetersiz bir şekilde çeşitlendirdiğini göstermektedir. Finansal literatür, yatırım fonlarının sermaye yatırımlarını çeşitlendirmek için etkili bir çözüm sunduğunu göstermektedir. Mümkünse, bu çeşitlendirme, tüm piyasalar portföylere tahsis edildiğinde en yüksek seviyededir (Gabbi, 2007).
- Profesyonel yönetim: Bir yatırım portföyünü yönetmek, fonun varlıklarının seçilmesini ve denetlenmesini gerektirir. Fonu yöneten yatırım uzmanları, bunu kesinlikle fonun temel yatırım hedefleri ve politikalarına uygun olarak yapmalıdır.
- Likidite: Yatırım fonu payları, fonun bir sonraki belirlenen pay başına net varlık değerinde satın alınabilir veya tasfiye edilebilir. Dahası, piyasa etkisinin doğrudan bir maliyeti yoktur, pay satın almak fiyatları yükseltme ve pay satmak fiyatları düşürme eğilimindedir. Paylar tasfiye edildiğinde de bir ücret alınmaz.
- Kolaylık: Yatırım fonu sahipliğinin basitlik ve kolaylık sağladığı şeklindeki dördüncü temel ilke, bir fonun paylarının ilk alındığı anda başlar. Satın alma işlemi, bir borsa aracı kurumunun bir temsilcisi tarafından yürütülen tek adımlı bir süreç yoluyla gerçekleştirilebilir veya hiçbir aracının dahil olmadığı çok adımlı bir işlem seçilebilir.

Yatırım fonlarının seçiminde yatırımcılar tarafından gözden geçirilmesi gereken fonun temel yapısal özellikleri aşağıdaki gibi sıralanabilir (Aktifportföy, 2021; İşportföy, 2021; SPK, 2021; Yalaman, 2019; Ziraatportföy, 2021):

- Fonun risk düzeyi,
- Fonun geçmiş performansı,

- Fonun kurucusu ve bu kurucunun yönettiği fonların türü,
- Fonun portföyünü yöneten portföy yöneticisi,
- Fonun en yakın tarihli portföy bileşimi ve stratejisi,
- Fonun yönetim ücreti oranı ve fon toplam gider oranı,
- Kurucunun fonlarının geçmiş dönemlerdeki performansı ve diğer fonlara göre başarı durumu,
- Fon katılma paylarının alınıp satılabileceği yerler, işlem saatleri ve alım satım şartları,
- Giriş – çıkış komisyonu olup olmamasıdır.

### **2.1.2. Yatırım fonlarının avantajları ve dezavantajları**

Yatırım fonlarının avantajları aşağıdaki gibi sıralanabilir (Russell, 2007):

- Küçük yatırımlar yeterli olmaktadır: Hem asgari mevcutlar hem de minimum başlangıç tutarları genellikle gerekli olsa da bireyler, yatırım fonlarına nispeten küçük miktarlarda para yatırabilirler. Böylelikle küçük yatırımcılar, bir faiz geliri karşılığında bankalara ve diğer finansal kurumlara fonlarını yatırarak dar ölçekte fayda elde etmek yerine küresel çaptaki ekonomik faaliyetin faydalarını elde edebilirler.
- Riskin yayılmasını sağlar: Bir yatırım portföyü bağlamında, riske ve dolayısıyla riskin yayılmasına yönelik iki husus vardır. Birincisi, portföy içindeki herhangi bir payın başarısızlığının tüm portföyün değeri üzerindeki etkisidir; ikincisi, genel haberlerin veya olayların, piyasadaki veya piyasanın belirli sektörleri üzerindeki tüm hisselerin fiyatları üzerindeki etkisidir. Bir portföy oluştururken bu iki yönün her birinin kendi tepkisi vardır.
- Profesyonel fon yönetimi sağlar: Birçok bireysel yatırımcı, servetlerini bir profesyonelle aynı derecede yetkinlikle yönetebilecek yeterli zamana ve uzmanlığa sahip değildir. Bir yatırım fonuna yatırılan para, çok çeşitli kaynaklara ve araştırma verilerine erişebilen ve piyasaya yakın olan, eğilimleri ve fırsatları ortaya çıktıkça tespit edebilen profesyonel fon yöneticileri tarafından yönetilir. Akıllarında başka konular olan bireysel yatırımcıların aksine, profesyonel fon yöneticileri fonun yatırım hedeflerine ulaşmasına konsantredir.



- Muamele ücretleri daha düşüktür: Bireysel katılımcının yatırımı küçük olabilsede birçok yatırımcının katkılarını tek bir fonda toplamak, yatırım yöneticisinin büyük miktarlarda ve dolayısıyla bireysel yatırımcının elde edebileceğinden daha düşük bir maliyetle işlem yapmasına olanak tanır.
- Kullanım kolaylığına sahiptir: Bir yatırım fonunda hisse veya birim satın almak ve satmak kolaydır ve bir aracıya ihtiyaç duymadan doğrudan yönetici ile gerçekleştirilebilir. Belirtilen işlemler telefonla ve giderek artan bir şekilde internet veya özel bir elektronik santral aracılığıyla gerçekleştirilebilir.
- Gelirin yeniden yatırıma dönüşmesini sağlar: Birçok yatırım fonu yöneticisi, genellikle ilk ücret uygulanmadan ek hisseler veya birimler satın alarak veya alternatif bir hisse veya birim türü kullanarak gelirin otomatik olarak yeniden yatırılmasını sağlayan planlar sunar.
- Vergilendirme esnekliğine sahiptir: Verginin ertelenmesi (ancak muafiyetin olmaması) ortak bir faydadır. Bazı ülkelerde yatırım fonları, ürünün yapımına dahil edilen vergi avantajlarından yararlanır.

Yatırım fonlarının dezavantajları ise aşağıdaki gibi sıralanabilir (Pozen ve Hamacher, 2015; Wankhade, 2016):

- Portföy üzerinde kontrole sahiplik yoktur: Fona yatırım yapan yatırımcılar, portföyün tüm kontrolünü onu yöneten yatırım fonu yöneticilerine bırakmaktadır. Yatırım fonları, yatırımcıların sermaye kazançlarının zamanlamasını da kontrol etmesine izin vermez. Bireysel hisse senetlerine veya tahvillerine sahip olan yatırımcılar, bir vergi kazancı veya kaybını muhasebeleştirmek için menkul kıymeti ne zaman satacaklarını seçebilirler. Ancak yatırım fonuna sahip yatırımcıların, yatırım fonu yöneticisi fonun elindeki menkul kıymetleri ne zaman satacağına karar verdiğinden, fona yatırımlarını azaltmamış olsalar bile aynı yıl net sermaye kazancı üzerinden vergi ödemeleri gerekir.
- Gelirin tahmin edilebilirliği daha düşüktür: Temettü ve faiz geliri normalde yatırım fonlarında daha az tahmin edilebilirdir. Bundan dolayı, sabit gelire öncelik veren yatırımcılar yatırımlarını yatırım fonlarına yapmaktan kaçınarak diğer yatırım araçlarına kaydırırlar. Tahviller itfa edilinceye kadar aynı faiz ödemesini düzenli olarak alacaklarını bilerek, tahvil alıp vadeye kadar ellerinde tutabilirler.

Bunun aksine, bir yatırım fonu sıklıkla tahvil alıp sattığı için, elde ettiği gelir, herhangi bir tarihte sahip olunan menkul kıymetlerin belirli kombinasyonuna bağlı olarak değişecektir.


- Kısa vadeli sermaye kazançları vergiye tabidir: Yatırım fonuna yatırım yapan yatırımcıların sermaye kazançlarının vergiye tabi tutulmaması için yatırım yaptıkları fonun işletildiği ülkeye has asgari bir süre yatırımlarına dokunmamaları gerekir.
- Çeşitli maliyet ve giderlere sebep olur: Bazı yatırım fonlarına sahip olmak isteyen yatırımcılar, tüm satın alımlarında fona girme maliyetine katlanmak zorundadır. Ayrıca, tüm yatırım fonları, yatırımcılarından yıllık giderler talep ederler. Gider oranı yüzde olarak ifade edilir ve yatırımcıların hesap değerlerinin bir kısmı olarak yıllık olarak ödedikleri tutardır. Yıllık gider oranı yönetilen fonlar için ortalama %1,5 civarındadır.
- Aşırı çeşitlendirme birtakım olumsuzlukları da beraberinde getirir: Çeşitlendirmenin pek çok faydası olmasına rağmen, aşırı çeşitlenmenin dezavantajları da vardır. Yatırımcının elinde ne kadar çok menkul kıymet varsa, yatırımcının genel portföyündeki bireysel getirilerini hissetme olasılığı o kadar düşük olur. Bunun anlamı, risk azalacak olsa da kazanç potansiyeli de azalacaktır. Bu, çeşitlendirmeyle anlaşılan bir değiş tokuş olabilir, ancak çok fazla çeşitlendirme, ilk etapta yatırımcının piyasaya maruz kalma isteğini ortadan kaldıracaktır.
- Yatırım esnasında nakit bulundurma gereksinimi vardır: Yatırım fonlarının, yatırımcı itfalarını karşılamak ve satın alımlar için likiditeyi korumak için varlıkları nakit olarak tutmaları gerekir. Bundan dolayı yatırımcılar fonları ellerinde tutarlarken belirli periyotlarla nakit ödeme yapmaları gerekir. Bunun sebebi yatırım yapılıp yapılmadığına bakılmaksızın yıllık harcamaların tüm fon varlıkları üzerinden değerlendirilmesidir.
- Kişiselleştirme yoktur: Yatırım fonlarının son bir dezavantajı da herhangi bir kişiselleştirmeye imkân tanımamasıdır. Bir fondaki tüm yatırımcılar aynı anlaşmayı almaktadır.

### 2.1.3. Yatırım fonlarının işletilmesi

Finansta temel amaç, ekonomideki finansal kaynakların verimli bir şekilde tahsis edilmesidir. Bir yandan, finansman ihtiyacı olan ekonomik birimler (borçlular veya firmalar) yatırım projelerini sürdürmek için birbirleriyle sermaye için rekabet ederler. Amaçları sermaye maliyetlerini en aza indirmektir. Öte yandan, fon fazlası olan ekonomik birimler (tasarruf sahipleri veya yatırımcılar) finansal sermayelerini sunar ve getirilerini maksimize etmeye çalışır. Kusursuz bir piyasada, firmaların sermaye maliyetleri ve yatırımcıların getirileri eşit olacak ve yatırım fonları gibi araclara gerek kalmayacaktır. Ancak piyasanın kusursuz olmamasından dolayı organize sermaye piyasaları, bankalar, yatırım fonları ve diğer araçlar firmalar ile yatırımcılar arasında bir köprü vazifesi görmektedir. Yatırım fonlarının piyasadaki konumu Şekil 2.2’de gösterilmiştir. Yatırım fonlarının iki temel fonksiyonu vardır. Birincisi, çeşitlendirilmiş bir menkul kıymet sepetine likit erişim sağlamak ve ikincisi, bireysel yatırımcılardan daha düşük bir maliyetle bilgi toplamak ve işlemektir. İlk fonksiyon, menkul kıymetlerin lot büyüklüğü ile risk, vade ve likiditesi açısından farklılıkları azaltırken, ikinci fonksiyon asimetrik bilgiden kaynaklanan maliyetleri azaltır (Lückoff, 2011).



Şekil 2.2. Ekonomide finansal kaynakların tahsisi (Lückoff, 2011)



**Şekil 2.3.** Fon süreç akışı (Loader, 2007)

Şekil 2.3 bir fonla ilişkili genel süreç akışlarını göstermektedir. Şekilde gösterilen iş akışında yürütülen işlemler, fonun kendi payları veya birimlerindeki işlemlerle başlar. Fonun idari politikasına ve yatırım hedefine bağlı olarak faaliyet hacminde bir fark olacaktır. Bununla birlikte, pay ve birimlerin alım ve satımlarının doğru kaydı hayati önem taşımaktadır. Görev genellikle transfer acentesinin çalışma alanına girmektedir.

Fon kaydının önemli bir yönü, net bir para girişi veya çıkışı göstererek fondaki nakit akışı ile ilgili hayati veriler sağlamasıdır. Burada önemli olan, yatırımcılar tarafından pay veya birimlerin itfasından kaynaklanan nakit çıkışının bir sonucu olarak bir ihtiyaç olup olmadığıdır. Hisselerin veya birimlerin itfası her zaman fondaki varlıkların nakde çevrilmesi için bir ihtiyaç yaratmayacaktır. Ayrıca kapatılan bir fon, ihraç edilen paylarda aynı dalgalanmaya tabi olmayacak ve bu nedenle pay alım ve satımıyla ilgili bir nakit akışına sahip olmayacaktır. Bir fondaki nakit hareketleri, yönetici tarafından varlıkların alım satımından kaynaklanan uzlaştırma tutarlarını, temettü ve faiz gibi gelirleri, belirli türdeki kurumsal eylemlerin sonucunu ve ödenmesi gereken ücretleri de içerir. Diğer bir önemli uzlaşma, yöneticinin kayıtlarına göre fonun varlık pozisyonları ve saklama görevlileri tarafından gösterilen fonun faaliyetleri ve pozisyonları ile ilgilidir. Fon kaydı ve nakit pozisyonu da açıkça iki hayati uzlaşmadır. Fiyatlandırma ve değerlemeler yönetici için pek çok zorluk teşkil etmektedir. Kullanılan ürünlerin bilgisi ve değerlerini nasıl elde ettikleri açıkça önemlidir. Güvenilir fiyatlara en iyi kaynaklardan ulaşmak ile

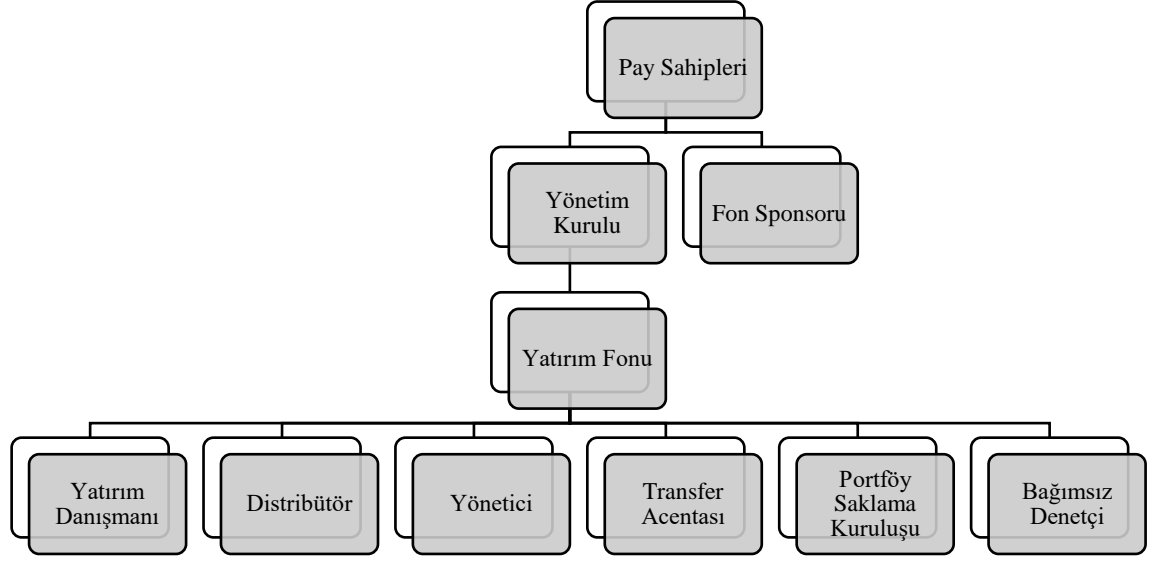
yeterli fiyatlandırma politikasına ve kontrollere sahip olmak da hayati önem taşımaktadır (Loader, 2007).

#### **2.1.4. Yatırım fonu organizasyonu**

Yatırım fonunun organizasyonunda yer alan hizmet sağlayıcıları Şekil 2.4’te gösterilmiş olup aşağıdaki gibi açıklanabilir (Haslem, 2003):

- Pay sahipleri: Payları elinde tutan yatırımcılardır.
- Fon Sponsoru: Fon sponsorları, her bir yatırım ürününün kurulumu için gerekli finansmanı sağlayan yatırımcı kategorileridir. Çoğu zaman fon sponsoru, kendi parasının bir kısmını, pay sahiplerinin çıkarlarının uyumlu olmasını sağlamak, bağlılık göstermek ve işe başlamak için ilk fonlamayı garanti etmek için yeni bir birime yatırır. Fonlar sponsor olup yürütüldükten sonra fonların pazarlanabileceği hedef grup, düzenleyiciler ve düzenleyici yönergeler tarafından tanımlanır (Mattig, 2009).
- Yönetim kurulu / müteveli heyeti: Fon için fon yöneticilerini ve diğer hizmet sağlayıcılarını işe alma sorumluluğu yönetim kurulu veya müteveli heyetine verilmiştir. Yönetim kurulu, fonun yatırımcılarının menfaatine en iyi şekilde yönetilmesinin sağlanmasında aktif rol oynamaktadır. İç gözetim mekanizması yönetim kuruluna verilmiştir. Dış gözetim, Sermaye Piyasası Kurulu tarafından sağlanmaktadır. Yönetim kurulu, hizmet sağlayıcılarla yapılan önemli sözleşmeleri inceler ve onaylar ve fonun finansal hizmetler endüstrisini yöneten menkul kıymetler yasalarına uygunluğunu sağlayan politika ve prosedürleri onaylar (Kumar, 2014).
- Yatırım danışmanı: Yatırım danışmanı, fon yatırım hedefleri, politikaları ve sınırlamaları ile tutarlı araştırma ve portföy yönetimi hizmetleri sağlar. Fonksiyonları arasında yatırım tarzı ve stratejilerinin oluşturulması ve uygulanması, güvenlik analizi, piyasa ve ekonomik analiz, portföy tahsisi, menkul kıymet alım / satım kararları ve performans değerlendirmesi yer alır.
- Distribütör: Distribütör komisyoncu-satıcı olarak hisselerin doğrudan ve / veya dolaylı olarak yatırımcılara dağıtımını sağlar, fon yayınlarını dağıtır, fon pazarlaması ve reklamcılığı gerçekleştirir.

- Yönetici: Yönetici, yönetim ve düzenleyici gözetim sağlar, diğer idari hizmet sağlayıcıların performansını inceler ve raporlar, fon düzenlemelerine uygunluğu sağlar. Bu gibi hizmetlerin yanında ofis, ekipman ve personel masraflarını ödeyebilir, genel muhasebe hizmetleri sağlayabilir ve vergi, hissedar ve bunun gibi diğer raporları hazırlayabilir.
- Transfer acentesi: Transfer acentesi; hissedar işlem taleplerini yerine getirir ve hissedar işlemlerinden ödeme alır ve yetkilendirir, hissedar hesabı ve işlem kayıtlarını tutar, birçok hissedar hizmeti sağlar, hesap ve işlem beyanları, yıllık ve altı aylık raporlar, prospektüs, vekaletname beyanları ve bilgilendirici materyaller dahil olmak üzere hissedar iletişimi sağlar, genellikle hissedar dağıtımları için ödeme aracı olarak hizmet eder.
- Portföy saklama kuruluşu: Portföy saklama kuruluşu, portföy nakitlerini ve menkul kıymetleri güvenli bir şekilde muhafaza eder, portföy işlemlerini gerçekleştirir, nakit ve menkul kıymetler alır ve yetkili nakit ödemeler ve teminat teslimatları yapar, portföy faizi ve temettü toplar, yetkili harcamaları, hissedar itfalarını ve ödemeleri gerçekleştirir ve ilgili kayıtları tutar.
- Bağımsız Denetçi: Bir bütün olarak finansal tabloların, hata veya hile kaynaklı önemli bir yanlışlık içerip içermediğine ilişkin makul güvence elde eden ve böylece finansal tabloların tüm önemli yönleriyle geçerli finansal raporlama çerçevesine uygun olarak hazırlanıp hazırlanmadığına dair bir görüş bildiren ve bulgularına uygun olarak, finansal tablolar hakkında raporlama yapan kişi veya kuruluşlardır (Kamu-Gözetimi-Kurumu, 2020). Bağımsız denetçiler, kontrollerdeki zayıflıkları aydınlatılabilmekte ve fon için risk oluşturabilecek sorunları belirleyebilmektedir. Denetçiler, çeşitli fon muhasebesi, fiyatlandırma ve değerlendirme sorunları gibi ilgili konularda bağımsız görüş sağlar.



**Şekil 2.4.** Tipik bir yatırım fonu kompleksi (Simpson, 2014)

### 2.1.5. Yatırım fonlarının yatırım hedefine göre sınıflandırılması

Yatırım fonları yatırım hedeflerine göre aşağıdaki başlıklarda görüldüğü üzere sınıflandırılabilir.

- Borçlanma araçları fonları: Gelir fonları olarak da bilinen bu fonlar, yalnızca hükümetler tarafından ihraç edilen sabit getirili menkul kıymetlere değil, aynı zamanda özel şirketler, bankalar ve finans kurumları ve altyapı şirketleri ve kamu hizmetleri gibi diğer kuruluşlar tarafından ihraç edilenlere de yatırım yapmaktadır. Bu araçlar, hisse senetlerine kıyasla daha düşük risk taşır ve istikrarlı bir gelir sağlama eğilimindedir. Bununla birlikte, bir para piyasası fonuyla karşılaştırıldığında, çoğu borçlanma araçları fonunun daha fazla piyasa riski veya fiyat riski ve kredi riski vardır (Parameswaran, 2010).
- Hisse senedi fonları: Hisse senedi yatırım fonu, payları gün içinde borsalarda piyasa tarafından belirlenen fiyatlarla işlem gören, tipik olarak açık uçlu fonlardır. Halka açık herhangi bir şirketin hisseleri gibi, yatırımcılar bir komisyoncu aracılığıyla hisse senedi yatırım fon paylarını satın alabilir veya satabilir. Hisse senedi yatırım fonlarının çoğu, finansal endekslere bağlıdır ve belirli yerel,

sektörel, bölgesel veya uluslararası endekslerin performansını çoğaltmaya çalışır (Baker vd., 2015).

- Kıymetli madenler fonları: Kıymetli madenler fonları altın ve diğer değerli metallere yatırım yapmaktadır. Bu emtialara yatırım yapmak risklidir, çünkü kıymetli madenlerin fiyatı borsanın tam tersini yapma eğilimindedir. Örneğin borsa yükselirse kıymetli madenlerin fiyatı düşer. Yine de portföyde değerli metallere küçük bir yatırım yapmak, hisse senedi fiyatlarında herhangi bir düşüş olması durumunda portföyü dengeleyeceğinden iyi bir fikir olarak kabul edilir (Kjelle, 2014).
- Fon sepeti fonları: Fon sepeti fonları, bir grup en iyi performans gösteren fona yatırım yapmayı amaçlayan bir yatırım fonudur. İdeal olarak, bu tür bir fon, kısa vadeli piyasa eğilimlerinden bağımsız olarak farklı varlık sınıfları, sektörler ve ülkeler arasında çeşitlendirme ve varlık tahsisi sunmaktadır. Fon sepeti fonları yatırımcılara belirli fonları araştırmak ve fon yöneticilerinin kayıtlarını incelemek zorunda kalmak yerine, belirli bir yatırım hedefini yerine getiren en iyi kayıtlara sahip fonları seçmektedir (Mobius, 2007).
- Para piyasası fonları: Para piyasası fonu, çeşitli para piyasası menkul kıymetlerine (kısa vadeli borçlanma araçları) bir para havuzunun yatırıldığı, günlük faizleri birleştiren ve hissedarlara aylık olarak temettü ödeyen bir tür yatırım fonu türüdür (Downes ve Goodman, 2003). Para piyasası fonları, ticari senetlere, banka kabullerine, geri alım anlaşmalarına, devlet tahvillerine, mevduat sertifikalarına ve diğer yüksek derecede likit ve güvenli menkul kıymetlere yatırım yapan ve para piyasası faiz oranlarını ödeyen yatırım fonlarıdır (Latko, 2003). Para piyasası fonları çok güvenli olmasına rağmen, uzun vadeli getirileri tahvillerden daha düşük ve hisse senetlerinden çok daha düşük getirilere sahiptir. Bu nedenle, büyümeden çok güvenlik arayan yatırımcılar için en iyisidir. Bazı para piyasası fonları vergilendirilebilirken bazıları da gelir vergisinden muaftır. Genel olarak, vergiden muaf fonlar vergilendirilebilir fonlardan daha düşük getiri sağlar (Kandziolka, 2012).
- Katılım fonları: Portföyünün tamamı devamlı olarak, kira sertifikaları, katılma hesapları, ortaklık payları, altın ve diğer kıymetli madenler ile sermaye piyasası kurulunca uygun görülen diğer faize dayalı olmayan para ve sermaye piyasası



araçlarından oluşan fonları kapsayan yatırım fonları, katılım fonu olarak adlandırılmaktadır (Mevzuat-Bilgi-Sistemi, 2012).

- Değişken fonlar: Fonun yatırım amacı, dengeli portföy dağılımı ile uzun vadede yatırımcılarına istikrarlı bir getiri sunmaktır. Değişken fon olması itibarıyla hisse senetlerinin yanında kamu veya özel sektör bonolarına yatırım yaparak portföy çeşitliliği sağlar ve hisse yoğun fonlara göre daha düşük oynaklığa sahiptir. Kontrollü risk alarak tahvil getirisi yanı sıra hisse senedinden yararlanmak isteyen yatırımcılar için uygun bir üründür (HSBC, 2021).
- Serbest fonlar: Serbest yatırım fonları, esas olarak geleneksel varlık sınıflarına yatırım yapan ve geleneksel aktif yöneticilere açık olmayan bir dizi yatırım stratejisi ve yaklaşımını izleyen ve aktif olarak yönetilen yatırım fonlarıdır. Serbest yatırım fonu yöneticileri, geleneksel yöneticilerin aksine genellikle tüm piyasa koşullarında pozitif getiri elde etmeyi ve bazen de yatırımcıların sermayesini korumayı amaçlamaktadır. Serbest yatırım fonu getirilerinin, yöneticilerin getiri yaratma becerilerine bağlı olduğu iddia edilmekte ve yöneticilerin performanslarının ölçülmesinin öneminin gündemin ön sıralarında yer almasına sebep olmaktadır (Iverson, 2013).
- Garantili yatırım fonları: Garantili yatırım fonu, yatırımcının başlangıç yatırımının büyük bir bölümünü, tamamını veya anapara üzerinde bir getiriyi belirli bir vade sonunda yatırımcılara geri ödemeyi garanti eden bir fondur. Yatırımcılara geri ödenmesi garanti edilen tutar, fonun unvanında ve izahnamesinde açık olarak belirtilir. Bu tür fonlarda, düzenlemelerde yer alan koşulları sağlayan bir garantör tarafından fona garanti verilir (Sayılgan, 2019).
- Yabancı menkul kıymetler fonları: Yabancı menkul kıymetler fonları, fonun yarısından fazlasını bir veya daha fazla yabancı menkul kıymetlere yatıran fonlardır (İnci vd., 2011). Yabancı menkul kıymet fonları uluslararası çeşitlilik sağlayan fonlardır. Yatırımcılar, yabancı menkul kıymetlere yatırım yapan fonların özel ek riskler içerdiğine dikkat etmelidir. Bu riskler arasında, bunlarla sınırlı olmamak üzere, döviz riski, politik risk ve değişen muhasebe standartlarıyla ilişkili riskler bulunur. Gelişmekte olan piyasalara yatırım yapmak bu riskleri artırabilmektedir (SEC, 2018).

- Dengeli veya Karma fonlar: Borçlanma araçları ve hisse senetlerinden oluşan bir portföyü vardır. Borç ve öz kaynaklarda aşağı yukarı eşit oranlara sahiptirler. Tipik olarak üç yönlü odakları vardır. Bunlar; anaparanın korunması, gelir elde edilmesi ve hem anaparanın hem de gelirin uzun vadeli büyümesidir (Parameswaran, 2010).
- Koruma amaçlı fonlar: Koruma amaçlı yatırım fonları tarafından yönetilen varlık tutarının, finansal piyasalardaki bütün varlıkların oldukça küçük bir kısmını oluşturmasına rağmen, koruma amaçlı yatırım fonlarının finansal piyasalardaki aktif ve etkin rolleri, yatırım amaçlı yatırım fonlarını global finansal piyasalarda giderek daha önemli bir piyasa oyuncusu konumuna getirmektedir (Anbar, 2011).

#### **2.1.6. Yatırım fonlarının idari politikaya göre sınıflandırılması**

Yatırım fonları idari politikaya göre aşağıdaki gibi sınıflandırılabilir:

- Açık uçlu (sonlu) yatırım fonu: Her fon belirli bir pay tutarı üzerinden Sermaye Piyasası Kurulundan izin alınarak kayda alınmaktadır. Fonun toplam pay sayısı piyasaya sürülebilecek azami fon tutarını göstermektedir. Bir anlamda fonun belirli miktarda bir sermayesi olduğu kabul edilebilir. Bu bağlamda açık uçlu yatırım fonları, sermayesi sabit olmayan malvarlığı olarak tanımlanmaktadır. Yatırımcılar tarafından talep edildiğinde talebin seviyesine göre pay sayısı artırılmakta, yatırımcılar tarafından paylar fona iade edildiğinde ise pay sayısı azalmaktadır. Açık uçlu fonlar borsada listelenmez. Yatırımcılar istedikleri zaman istedikleri sayıda fonu alıp satabilirler (Şahin vd., 2018).
- Kapalı uçlu (sonlu) yatırım fonu: Kapalı uçlu fonlar, fona yeni yatırımlar almayan veya yatırımcı hisselerini kullanmayan, profesyonelce yönetilen yatırımcı parası havuzlarıdır. Bu fonların hisseleri, organize veya tezgah üstü borsalarda alım satım yapıldığı için adi hisse senedi gibi hisse senedi hisselerine benzemektedir (Shefrin, 2013). Bu plan kapsamında, fon toplama yalnızca sınırlı bir süre için açıktır ve genellikle bir ay ile üç ay arasındadır. Bu plan kapsamında fonun tahsilatı ve birim sayısı önceden belirlenir. Fon toplama tutarı önceden belirlenen seviyeye ulaştığında, yatırımcıların girişi kapatılır. Kapalı uçlu fonlar,

yatırımcıların istedikleri zaman para çekmelerine izin vermez. Genellikle kapalı uçlu fonlar ikincil piyasalarda listelenmektedir (Hiriyappa, 2008).

- Aralıklı fonlar: Aralıklı fonlar, açık uçlu ve kapalı uçlu fonlar arasında bir tür orta yol niteliğindedir. Paylar veya birimler ihraç edildikleri ve geri alındıkları için teknik olarak açık uçlu fonlar olsalar da yalnızca sınırlı aralıklarla, genellikle en az yılda bir kez yapılırlar. Düzenlemeler bunun yapılabilmesi parametreleri belirlerken, fonların kendileri ek olarak (ve buna izin verilmesi koşuluyla) yalnızca ihraç ve itfa için açık oldukları süreleri değil, aynı zamanda sayı veya değeri de sınırlayabilir. Ek olarak, bazı aralıklı fonlar ise herhangi bir satın alma veya geri alma talebinin önceden bildirilmesini gerektirebilir (St Giles vd., 2003).

### **2.1.7. Yatırım fonları risk faktörleri**

Yatırım fonlarına yatırım yapmanın doğurduğu riskler aşağıdaki gibi sıralanabilir (Trahair, 2009):

- Kredi Riski: Kredi riski, bir kredi işleminde borçlunun ya da bir sözleşmede karşı tarafın yükümlülüklerini tam olarak ve zamanında yerine getirmeme olasılığından kaynaklanan zarar etme ihtimali olarak tanımlanabilir (Altay, 2015).
- Türev Riski: Bazı fonların türevlerinin, genellikle riskten kaçınmak amacıyla kullanılan sözleşmeleri kullanma özgürlüğü vardır. Fonun açıklaması bunun yapıp yapılmadığını belirtmektedir.
- Yükselen Piyasalar Riski: Gelişmiş piyasa ülkelerinde bulunmayan yabancı ihraççıların menkul kıymetleri, gelişmiş piyasa ülkelerindeki yabancı ihraççıların menkul kıymetleri ile aynı risklere tabidir, ancak bu riskler daha belirgin olabilir. Riskler daha büyüktür çünkü sosyal, politik, yasal ve ekonomik sistemleri genellikle daha az istikrarlıdır ve değişim ve düzenleyici etkinliği gelişmiş ülkelere göre genellikle daha düşüktür. Bu faktörler, gelişmekte olan piyasa yatırımlarını gelişmiş piyasalardaki yatırımlardan daha değişken ve daha az likit hale getirebilir (White, 2020).
- Özsermaye Riski: Çok basit bir şekilde, bir pay sepeti veya pay, piyasa değerinde yükselirse, ona yatırım yapan fonlar da yükselir. Dolayısıyla, güçlü ekonomi

olumlu şirket görünümü doğurur, genel olarak pay fiyatlarının yükselmesini sağlar. Zayıf ekonomi, cansız ya da olumsuz şirket görünümüne sebep olur ve genel olarak pay fiyatlarının düşmesine yol açar.

- **Döviz Kuru Riski:** Yatırımcılar, dayanak varlıkların yatırım fonunun para biriminden farklı bir para biriminde alınıp satılması veya fonun kendi para biriminden farklı bir para biriminde kurulması durumunda döviz kuru riskine maruz kalabilir. Döviz kurlarının hareketi yatırımcı için bir endişe kaynağıdır. Bunun yanı sıra bir yatırım fonunun yabancı para cinsinden varlıklara da yatırım yapması kur riski doğurabilir. Fonların performansı ve riskliliği, yerli ve yabancı paraya ait döviz kurunun gelişimine bağlıdır (Pfeiferová ve Kuchařová, 2020).
- **Yabancı Sermaye Riski:** Yabancı menkul kıymetlerin değeri, yabancı hükümetlerin politikalarından ve siyasi, ekonomik veya sosyal istikrarsızlıktan etkilenebilir. Türkiye menşeli şirketlere göre yabancı şirketler hakkında daha az bilgi olabilir ve yabancı finans piyasalarında daha düşük hükümet denetimi ve düzenleme standartları olabilir. Bu menkul kıymetleri tutan bir fon, Türkiye dışındaki yargı bölgelerinde yasal hakları uygulamakta zorluk çekebilir.
- **Faiz Oranı Riski:** Bir tahvilin faiz oranı ihraç edildiğinde belirlenir. Faiz oranları düşerse, mevcut bir tahvilin fiyatı yükselecektir. Bunun sebebi ise yeni tahvillerden daha yüksek bir oran ödüyor olacağından daha değerli olmasıdır. Bu durumun aksine, faiz oranları yükselirse, mevcut bir tahvilin ve bu tür tahvilleri tutan herhangi bir fonun değeri düşecektir. Dönüştürülebilir menkul kıymetler içeren fonlar da faiz oranı riski taşımaktadır.
- **Büyük Yatırımcı Riski:** Finansal kuruluşlar gibi büyük yatırımcılar, bir fonun menkul kıymetlerini kullanabilir veya satın alabilir. Bu tip eylemler, portföy yöneticisini portföyün kompozisyonunu önemli ölçüde değiştirmeye veya yatırımları uygun olmayan fiyatlarla alıp satmaya zorlayacak kadar önemli olabilir ve bu da getiriyi olumsuz etkileyebilir.
- **Likidite Riski:** Likidite riski, vadesi gelen mevduat ve diğer yükümlülüklerin karşılanması için yeterli düzeyde nakdin bulunmaması olarak ifade edilmektedir. Diğer bir ifadeyle, portföyün taahhütleri için gerekli kaynağın oluşturulmaması, varlığın vadesi dolduğunda karşılanamaması, borçlanmadaki aşırı faiz oranları gibi nedenlerden dolayı varlıkların pazar fiyatlarının altında satılması likidite

riskini ortaya çıkarmaktadır. Beklenmeyen kaynak çıkışları, aktif kalitesindeki bozulmalar, karlılıktaki düşüşler, döviz kurlarındaki değişimler ve ekonomik krizler de likidite riskini etkileyen sebepler arasında sayılmaktadır (Terzioğlu, 2018).

- **Düşük Dereceli Güvenlik Riski:** Bazı şirketler daha yüksek risk taşıdıkları için daha yüksek getiri oranı sunarlar. Yatırım derecesinin altında kredi notuna sahip olabilirler veya derecelendirilmemiş olabilirler. Bu yatırımların değerlendirilmesi zor olabilir. Çünkü piyasa kotasyonları mevcut değildir ve yüksek kaliteli yatırımlardan daha az likit olabilirler. Bu tip fonlar büyük kazanç veya kayıp potansiyeline sahiptirler.
- **Düzenleyici Riski:** Sağlık hizmetleri ve telekomünikasyon gibi endüstriler yoğun bir şekilde düzenlenir ve hükümetten fon alabilir. Deregülasyon veya azaltılan hükümet finansmanı gibi hükümet politikasındaki değişiklikler, bu sektörlerdeki şirketleri büyük ölçüde etkileyebilir. Bu nedenle bu yatırımları satın alan fonların değerleri önemli ölçüde artabilir veya düşebilir.
- **Geri Alım / Ters Geri Alım Anlaşmaları Riski:** Geri alım anlaşması, bir menkul kıymetin tek bir fiyattan satılmasını ve aynı anda daha düşük bir fiyattan geri alınmasını kabul eder. Ters geri alım anlaşması ise, bir menkul kıymeti tek bir fiyattan satın almayı ve daha yüksek bir fiyattan geri satmayı kabul eder. Bu pek çok risk yaratır. Daha sonra fonlar, teminatları dengeleyerek ve bu işlemler için bir dizi koşul belirleyerek bu riskleri azaltmak için birtakım işlemler gerçekleştirir.
- **Menkul Kıymet Ödünç Verme Riski:** Bazı fonlar, portföy menkul kıymetlerinin bir kısmını nitelikli bir borçluya veya bir ücret karşılığında ve belirli bir süre için teminat veren borçlulara ödünç verebilir. Bu fonlar, bir borçlunun yükümlülüklerini yerine getirememesi riskini taşır, fonda tuttuğu teminatı ödünç verdiği menkul kıymetlerden daha az değerinde bırakır ve fon için bir zarara neden olur. Bu riski sınırlandırmak için ne kadar ve ne tür teminat tutulabileceği, fonun bu tür işlemler yoluyla ne kadar borç verebileceği ve herhangi bir borçluya ne kadar maruz kalabileceği konusunda bir üst sınır belirlenir.
- **Seri Riski:** Fonlarda, her biri kendi ücret ve masraflarına sahip ve diğer serilerden ayrı olarak izlenen birkaç birim dizisi olabilir. Bir dizi, fon varlıkları içindeki

orantılı payına bağılı olarak harcama payını ödeyemezse, başka bir dizinin yardımcı olması gerekebilir. Bu gibi durumlarda yatırım getirisi muhtemelen zarar görecektir.

- **Daha Küçük Şirket Riski:** Daha küçük bir şirket tarafından ihraç edilen menkul kıymetlerin değerinin, dar pazarlar ve küçük şirketlerin sınırlı kaynakları nedeniyle, daha yaygın menkul kıymetlere kıyasla bazen hızlı ve tahmin edilemeyecek şekilde artması veya azalması riskidir. Bir fonun küçük şirketlere yaptığı yatırımlar, onu daha yüksek düzeyde kredi, piyasa ve ihraççı riskine maruz bırakır (SEC, 2017).
- **Dayanak Fon Riski:** Bir dayanak fon, üst fon tarafından yapılan yatırımın boyutuna ve bu yatırımın itfasının zamanlamasına bağılı olarak büyük bir itfa emrini karşılamak için portföy varlıklarını önemli ölçüde değiştirmeye zorlanabilir ve bu durum temeldeki fonun performansı üzerine olumsuz bir etki yaratabilir.

## **2.2. Portföy Yönetimi**

### **2.2.1. Portföy ve portföy yönetimi kavramı**

Yatırımcının belirli bir amaç doğrultusunda tek bir menkul kıymet yerine, birden fazla menkul kıymete yatırım yapması durumunda ortaya bir portföy çıkmaktadır (Ergün, 2020). Pay senedi, tahvil ve yatırım fonu gibi çeşitli finansal varlıkların bir araya getirilmesiyle oluşan; varlıkların çeşitlendirilmesiyle yatırımcılara düşük riskli ve yüksek getirili yatırım olanağı sağlayan finansal varlıklar portföy olarak adlandırılmaktadır (Özarslan, 2018).

Bir terim olarak portföy, genellikle finansla ve özellikle beklenen getiri ve risk ile karakterize edilen piyasada ticarete konu olan varlıklara yatırım yapmak için öneriler sağlayan optimizasyon modelleriyle ilişkilendirilir. Bu tür modellerin evrimi, ünlü Markowitz ortalama varyans modeli ile başlamıştır. 1950'lerin başında, Profesör Harry Markowitz'in araştırması, çeşitlendirmenin risk azaltma faydalarını ölçmek için bir çerçeve sağlamıştır. Yatırım riskinin ölçüsü olarak getirilerin standart sapmasını kullanarak, riskli menkul kıymetleri bir portföyde birleştirmenin portföyün riskini ve

beklenen getiriyi nasıl etkilediğini araştırmıştır. Modelin önemli bir sonucu, riskli varlıkların getirileri mükemmel bir şekilde pozitif olarak ilişkilendirilmedikçe, varlıklar aralarında çeşitlendirilerek risk azaltılacaktır. 1960'lı yıllarda optimizasyon teknikleri, istenen risk ve getiri özelliklerini sergileyecek yatırım portföylerinin oluşturulmasında önemli bir hale gelmiştir. Treynor, Sharpe, Mossin ve Lintner bağımsız olarak ortalama varyans modelini modern portföy teorisi olarak bilinen yaklaşıma genişletmiştir. Modern portföy teorisi, her bir portföyün piyasa riskinin doğrusal bir fonksiyonu olan menkul kıymetler ve portföyler için denge beklenen getirileri ile sonuçlanmaktadır (Salo vd., 2011).

Portföy yönetimi ise, risk ve beklenen getiri tercihlerine göre finansal varlıkların seçilerek portföy oluşturulması, oluşturulan portföydeki varlıkların değiştirilmesi, portföydeki varlıkların oranlarının ihtiyaca göre güncellenmesi, portföyden varlık satılması veya portföye yeni varlık alınması gibi işlemlerle portföyden en yüksek başarıyı elde etmek üzere yatırım kararları alınmasına dayanan bir varlık yönetim şeklidir (Gündoğdu, 2018).

### **2.2.2. Portföy yöneticisi kavramı**

Tasarruflarını finansal piyasalarda değerlendirmek isteyen ancak yeterli bilgi, deneyim veya zamana sahip olmayan bireysel yatırımcılar, kendi portföylerini oluşturmak yerine kurumsal yatırımcıların sunduğu hizmetlerden faydalanmaktadırlar. Kurumsal yatırımcı kavramı, belirli bir amacı gerçekleştirmek için kurulmuş ve üçüncü kişiler adına finansal araçların alım satımı ile uğraşan tüzel kişilikler olarak tanımlanmaktadır (Orçun, 2016a).

Kurumsal yatırımcıların sağladığı katkılar aşağıdaki gibi sıralanabilir (Usul ve Kocabıyık, 2010):

- Ekonomik büyümenin hızlandırılması,
- Tasarrufların birikimlerini şeffaf ve güvenli bir ortamda değerlendirmelerine olanak sağlaması,
- Sermayenin tabana yayılması,
- Kayıt dışı ekonominin azaltılması,
- Uzun vadeli yatırım ve fonlama imkanlarının artırılması,

- Ekonominin risklerinin ve kırılganlığının azalmasıdır.

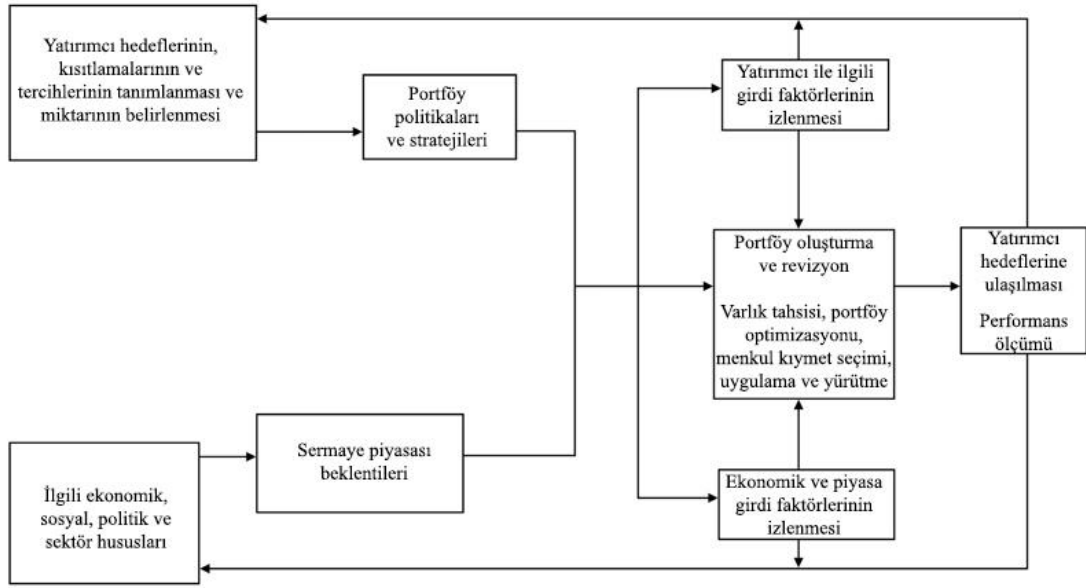
Kurumsal yatırım firmaları, kurumlarında profesyonel fon yöneticileri istihdam etmektedir. Bir fon yöneticisi genellikle bir yatırım uzmanıdır ve fonları profesyonel bir şekilde yönetmek için sermaye piyasaları hakkında derinlemesine bir bilgiye sahip olması gerekir. Yatırım fonlarının, ideal olarak, hissedarlarının fonlarını yöneten ve çeşitlendirilmiş bir portföye yatırım yapan ve böylelikle tek bir menkul kıymete yatırım yapma riskini azaltan bir iş nitelikleri ve profesyonel içgörüyü sahip varlık yönetimi şirketleri tarafından yönetildiği bilinmektedir. Yatırımcıların bir yatırım fonuna yatırım yaparak elde edebilecekleri doğal portföy çeşitliliği, likidite ve şeffaflığın cazibesi ile birleştiğinde, tüm dünyada yatırım fonu endüstrisinin sürekli büyümesinde önemli bir faktör olmuştur. Varlık yönetimi şirketlerinin ve bunların yatırım fonu kuruluşlarının fon yöneticilerinin temel amacı, yatırımcılar için riski en aza indirmektir. Bir yatırımcı, yatırımın likiditesini kolaylaştıran herhangi bir yatırım fonu planını seçme seçeneğine sahiptir. Ancak, fon yöneticisinin performansının değerlendirilmesi, yönettiği planların ve portföyün performansına bağlıdır ve portföy yöneticileri kadar yatırımcılar için de hayati önem taşır. Bir fon yöneticisinin başarısı, bilgi birikimine ve doğru miktarda, doğru yatırım türüne doğru zamanda yatırım yapma becerisine dayanan yatırım faaliyetine bağlıdır. Mevcut dinamik küresel ortamda, yatırım yollarını keşfetmek büyük önem taşımaktadır. Yatırım fonlarının yönetim tarzı belirli bir süre içinde geliştirilir ve büyük ölçüde deneyim ve uzun hazırlıklardan etkilenir (Sekhar, 2017).

Portföy yöneticisi, bilgi sürecinin dinamik doğasını anlar ve bu bilgiyi en uygun varlık hakkında getiri tahminleri yapmak için kullanır (Grinold ve Kahn, 2019). Yatırımcılar, piyasa getirilerinin üzerinde değer katan aktif fon yöneticileri bulmakta ciddi zorluklarla karşılaşmaktadır (Basilico ve Johnsen, 2019). Gerçekten aktif ve yetenekli yöneticiler, ücretler düşüldükten sonra pazarın üzerinde getiri sağlayabilmekte ve özellikle uzun vadede aktif olarak yönetilen stratejileriyle haklı olarak bir değer katabilmektedirler (Elmesseary, 2014).



### 2.2.3. Portföy yönetimi süreçleri

Portföy yönetimi süreci, müşterilerin belirtilen hedeflerini karşılamak için uygun bir portföy oluşturmak ve sürdürmek için tutarlı bir şekilde gerçekleştirilen entegre adımlar dizisidir. Portföy yönetimi sürecinin genel gösterimi, Şekil 2.5'te yer almaktadır. Portföy yönetimi süreci, her tür portföy yatırımı için geçerli olan dinamik ve esnek bir kavramdır (Maginn vd., 2007).



Şekil 2.5. Portföy yönetimi süreci (Maginn vd., 2007)

#### 2.2.3.1. Portföy amaçlarının ve kısıtlarının belirlenmesi

Portföy amaçlarının ve kısıtlarının belirlenmesi aşamasında, portföy yöneticileri yatırım amaçlarını ve politikalarını formüle eder, sermaye piyasası beklentilerini değerlendirir ve stratejik varlık tahsisleri oluşturur. Yatırım politikası beyanı, sürecin temelini oluşturur. Yatırım politikası beyanı, bir müşterinin getiri hedeflerini ve o müşterinin ilgili zaman ufkundaki risk toleransını; likidite ihtiyaçları, vergi değerlendirmeleri, yasal gereklilikler ve benzersiz koşullar gibi uygulanabilir kısıtlamalarla birlikte belirler. Yatırım politikası beyanı, müşterinin hedeflerini ve kısıtlamalarını açıkça belirtmelidir. Böylece yatırım politikası beyanı, müşterinin daha sonra görevlendireceği herhangi bir danışman veya portföy yöneticisi tarafından uygulanabilecek bir plana dönüşür. Uygun şekilde

geliştirilmiş bir yatırım politikası beyanı, portföy yönetimi sürecini düzenler ve stratejide geçici revizyonlara karşı güvence sağlamaya yardımcı olur. Yatırım politikası beyanı sermaye piyasası beklentileriyle birleştirildiğinde, stratejik varlık tahsisinin temelini oluşturmaktadır. Sermaye piyasası beklentileri, yatırım fonları gibi sermaye piyasası araçlarının risk ve getiri özellikleri ile ilgilidir. Stratejik varlık tahsisi, müşterinin uzun vadeli hedeflerine ve kısıtlamalarına ulaşmak için yatırım politikası beyanına izin verilen varlık sınıfları için kabul edilebilir riskler oluşturur (Xidonas vd., 2012).

Kesin terminoloji portföy yönetimi firmaları arasında farklılık gösterse de dört ana portföy amacı vardır. Bunlar anaparanın istikrarı, gelir, gelir artışı ve sermaye değerlemesi olup aşağıda detaylıca açıklanmıştır (Strong, 2008):

- Anapara istikrarı: Bazen bir portföyün lehtarının asıl müvekkiline karşı herhangi bir kaybetme şansı olamaz. Bunun nedeni kanun hükümleri, tüzük veya müşterinin riske karşı tutumu olabilir. Yatırımcı yatırdığı parayı kaybetme ihtimali istemediğinde, fon yöneticisi bu kişinin amacını anapara istikrarı olarak yorumlar. Anapara istikrarı en muhafazakâr portföy amacıdır ve uzun vadede en mütevazı getiriye sağlamaktadır.
- Gelir: Gelir amacı, anapara değerindeki periyodik düşümlere karşı özel bir yasaklama olmaması nedeniyle anapara istikrarından farklıdır. Burada amaç belirli bir risk karşılığında gelir elde etmektir.
- Gelir artışı: Gelir artışını birincil amaç olarak gören fonlar, genellikle yıllık gelirin en azından enflasyon oranında artmasını sağlamaya çalışır.
- Sermaye değerlemesi: Bir vergi mükellefi için, gerçekleşmemiş bir sermaye kazancı, gelirden daha değerlidir. Bazı yatırımcılar sahip oldukları portföyden ek gelir elde etmektense portföylerinin değer olarak büyümeye devam etmesini sağlamakla daha çok ilgilenmektedir. Bu tip yatırımcıların amacı, sermaye değerlemesidir.

Yatırım portföy yöneticisinin bir sonraki adımı, faaliyet göstermesi gereken özel koşulları belirlemektir. Portföy kısıtları aşağıdaki şekilde sınıflandırılabilir (Strong, 2008):

- Zaman ufku: Yatırımın işte olacağı sürenin uzunluğu, uygun varlık tahsisi için kritik öneme sahiptir. Altı ay içinde paraya ihtiyacı olan birinin portföyü, onlarca yıl pazarda kalacak bir portföyden farklı olmalıdır.
- Vergi durumu: Birçok yatırımcı için vergiler, ticaret maliyetlerinin en büyük bileşenidir. Vergi yükü bazı durumlarda yüzde 50'yi aşabilir. Durum böyle olduğunda, vergilendirilebilir tahvil ve temettü getirisi yüksek hisse senetlerinden kaçınmak mantıklı olabilir. Böyle bir oranda, vergi sonrası cari getiri, rapor edilen değer yalnızca yarısıdır. Bir hisse senedi satın kazanç elde etmek gerektiğinde, yönetici, vergi maliyetini en aza indirmek için genellikle aynı anda bazı kaybeden pozisyonları satmaya çalışacaktır.
- Likidite ihtiyaçları: Bazı portföyler, mal sahibine veya bir dizi yararlanıcıya istikrarlı bir gelir akışı sağlamalıdır. Yönetici, gerekli fonların zamanında hazır olmasını sağlamalıdır.
- Yasal hususlar: Bazı yatırım portföyleri, uygun varlıkların yasal hususlarıyla karşı karşıyadır. Kanun, fonun yüksek getirili tahviller tutmasını yasaklıyorsa, fon yöneticisinin tahvil derecelendirme değişikliklerini izlemesi gerekir. Diğer bir yaygın gereksinim ise minimum ödeme oranıdır. Bazı kuruluşlar, vergiden muaf statülerini sürdürmek için ortalama fon varlıklarının belirli bir yüzdesini ödemekle yükümlüdür.
- Özgün ihtiyaçlar ve özel koşullar: Yönetilen para yatırım yöneticisine değil müşteriye aittir. Müşteri, yöneticinininkinden oldukça farklı tercihlere sahip olabilir.

### **2.2.3.2. Sermaye piyasası beklentilerinin ölçülmesi**

Sermaye piyasası beklentilerinin belirlenmesi, yatırımlarda ve ekonomide deneyim ve uzmanlık gerektirmektedir. Büyük varlık yöneticileri sermaye piyasası beklentilerini geliştirme sorumluluğu olan bir araştırma birimine sahip olabilir. Varlık yöneticileri, başarılı tahminler yardımıyla riski iyi bir şekilde kontrol etmeye ve aktif olarak yönetilen

hesapların sonuçlarını iyileştirmeye çalışır. Aşağıda, sermaye piyasası beklentilerini belirlemeye yönelik bir çerçeve verilmiştir (Calverley vd., 2007):

- Uygulandıkları zaman ufku dahil olmak üzere ihtiyaç duyulan nihai beklenti kümesinin belirtilmesi: Analistin, verimli bir şekilde çalışabilmesi için, analizin belirli hedeflerini anlaması gerekir. Bu adımı daha da somut hale getirmek için, analist cevaplanması gereken soruları yazmalıdır. Bu adımı gerçekleştirmek, analistin özel ihtiyaçlarını, müşterinin kısıtlamalarına uygun şekilde dikkate alarak, endişe duyulan ilgili varlık sınıfları kümesi açısından formüle etmesini gerektirir. Çoğu durumda, yatırımcının yatırım politikası beyanı bu görevde rehberlik sağlayabilir.
- Tarihsel kayıtların araştırılması: Çoğu tahminin geçmişle bazı bağlantıları vardır. Geçmiş kayıtlar, birçok piyasa için varlığın yatırım özelliklerine ilişkin faydalı bilgiler içerir ve gelecekteki sonuçlar için bazı olası aralıklar önerir. Analist, ham tarihsel gerçeklerin ötesinde, varlık sınıfı getirilerini etkileyen faktörleri belirlemeye ve bu faktörlerin ne, ne zaman, nerede, neden ve nasıl olduğunu anlamaya çalışır. Böylece analist, iyi sonuçlara varmak için bir araya getirmesi gereken bilgi mozaigini daha iyi anlayacaktır.
- Kullanılacak yöntemlerin, modellerin ve bunların bilgi gereksinimlerinin belirtilmesi: Yatırımcı, sermaye piyasası analisti veya sermaye piyasası beklentilerini geliştirmekten sorumlu kişi, kullanılacak yöntemler ve modeller konusunda açık olmalı ve seçimi gerekçelendirebilmelidir. Bilgi gereksinimleri yöntemler hakkındaki karara bağlıdır.
- Bilgi gereksinimleri için en iyi kaynakların belirlenmesi
- Mevcut yatırım ortamının seçilen veri ve yöntemleri kullanarak, deneyim ve muhakeme uygulanarak yorumlanması: Analist, yatırım ve ekonomi sahnesinin farklı unsurlarını yorumlamada ortak bir varsayımlar kümesine göre çalıştığından emin olmalıdır. Böylece analistin sonuçları tutarlı olur. Analistin, verilerdeki çelişkili sinyalleri yorumlamak için çoğu kez muhakeme ve deneyim uygulaması gerekir.
- Sonuçların belgelenecek ihtiyaç duyulan beklentilerin sağlanması: Bunlar, ilk adımda ortaya konan sorulara analistin yanıtlarıdır. Yanıtlara, arkasındaki mantık ve varsayımlar eşlik etmelidir.

- Gerçek sonuçların izlenmesi ve beklentilerle karşılaştırılması: Beklenti belirleme sürecinin iyileştirilmesi için geri bildirim sağlanmalıdır.

### **2.2.3.3. Portföy (varlık karışımı) seçimi**

Portföy seçimi sürecinde, portföy amaçlarının ve kısıtlarının belirlenmesi ve sermaye piyasası beklentilerinin ölçülmesi aşamasında yapılan analizler sonucunda portföye alınacak finansal araçların seçimi yapılmaktadır. Portföy seçimi, portföy yatırımının değişik varlık sınıflarına bölünmesini ifade etmektedir. Bu aşamada hangi yatırım fonuna ne kadar yatırım yapılacağı saptanmaktadır (Kıyılar ve Akkaya, 2020).

Varlık tahsisi kararı, bir yatırımcının hisse senetleri, tahviller, nakit benzerleri gibi varlık sınıflarına koyacağı yatırım yapılabilir fonların yüzdesine karar vermeyi içermektedir. Bir varlık sınıfı içinde, oldukça çeşitlendirilmiş portföyler, zaman içinde benzer getiri sağlama eğiliminde olacaktır. Ancak, farklı varlık sınıflarının oldukça farklı sonuçlar üretmesi muhtemeldir. Bu nedenle, varlık dağılımındaki farklılıklar, zaman içinde portföy performansında farklılıklara neden olan temel faktör olacaktır.

Varlık tahsisi kararı verilirken göz önünde bulundurulması gereken önemli hususlar arasında yatırımcının getiri gereksinimleri, yatırımcının risk toleransı ve zaman ufku bulunur. Karar verme işlemi, yatırım yöneticisinin sermaye piyasaları ve münferit varlıklar hakkındaki beklentileri ile bağlantılı olarak gerçekleştirilir (Jones, 2013).

#### **2.2.3.3.1. Portföyün getirisinin hesaplanması**

Portföy getirisi, bir önceki döneme kıyasla portföy değerindeki artış oranıyla ölçülmektedir. Menkul kıymet yatırım fonlarının günlük getirileri hesaplanırken bu yöntem esas alınmaktadır. Her bir fonun işlem gördüğü gündeki kapanış fiyatları kullanılarak günlük getirileri Denklem 2.1 yardımıyla hesaplanmıştır (Arslan ve Arslan, 2010).


$$R_p = \frac{(P_{p,t} - P_{p,t-1})}{P_{p,t-1}} \quad (2.1)$$

Denklemden  $R_p$  portföyün getiri oranını,  $P_{p,t}$  portföyün t dönemindeki fiyatını ve  $P_{p,t-1}$  portföyün t-1 dönemindeki fiyatını temsil etmektedir.

### 2.2.3.3.2. Portföy riskinin hesaplanması

Riski iki bileşene ayırmak geleneksel bir uygulamadır. Bunlardan ilki, piyasa değeri değişikliklerinden kaynaklanan değerdeki değişikliği temsil eden sistematik risk veya piyasa riskidir. Sistematik risk, menkul kıymet seçimiyle bir miktar azaltılabilir. Ancak, sistematik riskin bu şekilde azaltılması, yatırımcının portföyü mükemmel şekilde çeşitlendirilmeyeceği için toplam riski artırabilir. Alternatif olarak, bir portföydeki sistematik riskin seviyesi, risksiz varlık ve piyasa portföyünün oranları değiştirilerek de değiştirilebilir.

İkinci risk türü, artık veya sistematik olmayan risktir. Bu risk şirkete (veya varlığa) özeldir ve piyasaya ne olduğundan bağımsızdır. Yatırımcının portföyü, her biri  $var(x)$  riskine sahip ve portföyün büyük bir yüzdesi menkul kıymet olmayan çok sayıda menkul kıymetten oluşuyorsa, sistematik olmayan risk  $\frac{var(X)}{n}$  ye eşittir. Eğer n çok büyükse, bu sistematik olmayan riskin bu çeşitlendirme stratejisi ile sifıra yaklaşması sağlanabilir. Şekil 2.6, toplam risk ve menkul kıymet eklemenin sistematik olmayan riski üzerindeki etkisini göstermektedir.



**Şekil 2.6.** Çeşitlendirme yoluyla risk azaltma (Kıyılar ve Akkaya, 2020)

Çeşitlendirmenin maliyetleri nispeten düşük olduğundan, yatırımcılar nispeten düşük bir sistematik olmayan risk yükü taşıdığı için bir menkul kıymet için daha fazla ödeme yapmaya istekli olmayacaklardır. Benzer şekilde, büyük miktarda sistematik olmayan risk taşıyan menkul kıymetler de ciddi bir fiyat dezavantajına maruz kalmayacaktır. Menkul kıymet fiyatları, portföylerini düşük maliyetle çeşitlendirebilen yatırımcıların faaliyetleri ile belirlenmektedir. Sistematik olmayan risk çeşitlendirilebilir çünkü her bir menkul kıymetin sistematik olmayan riski, diğer menkul kıymetlerin sistematik olmayan riskinden bağımsızdır. Her bir menkul kıymetin, portföyün çok küçük bir bölümünü oluşturduğu durumlarda, portföyün sistematik olmayan riski sıfıra yaklaşacaktır (Bierman Jr ve Smidt, 2007).

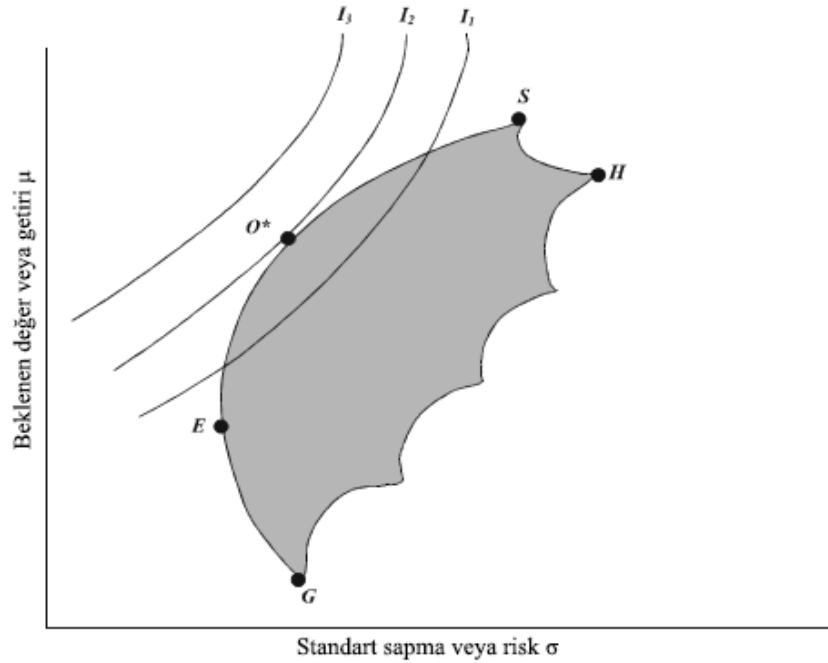
Risk, bir yatırımdan elde edilmesi beklenen getiriden farklı bir getiri elde etme olasılığını ifade etmektedir. Dolayısıyla, risk sadece kötü sonuçları değil (beklenenden daha düşük getiri), aynı zamanda iyi sonuçları da (beklenenden daha yüksek getiri) içerir. Bunların ilki aşağı yönlü risk, ikincisi ise yukarı yönlü risktir. Ancak risk ölçülürken ikisi de dikkate alınmaktadır. Finansa risk tanımının ruhu, en iyi şekilde, Şekil 2.7’de gösterilen Çince risk sembolleri üzerinde görülmektedir. İlk sembol “tehlike”, ikincisi ise “fırsat” sembolüdür ve riski bir tehlike ve fırsat karışımı yapar. Bu bakış açısıyla her yatırımcının ve işletmenin fırsatla birlikte gelen daha yüksek getiriler ile tehlikenin bir sonucu olarak üstlenilmesi gereken daha yüksek risk arasında yapması gereken ödünleşim net bir şekilde ifade edilmiştir. Finansal açıdan, tehlike risk, fırsat ise beklenen getiri

olarak adlandırılır. Genel amaç ise herhangi bir yatırımdaki tehlikeyi en iyi şekilde ölçmek ve ardından bu tehlikeyi telafi ederek fırsata dönüştürmektir (Damodaran, 2006).

危機

Şekil 2.7. Çince risk sembolleri (Damodaran, 2006)

Risk, negatif değerler içeren sonuçlarla karşılaşma şansı olduğu için, bir portföyün değerinin olasılık dağılımının standart sapması ile ölçülen değerlerdeki oynaklıkla temsil edilebilir. Tipik bir portföy kümesi için, bu portföylerin değer olasılık dağılımlarının standart sapmalarıyla ( $\sigma$ 'lar) temsil edilen riskler ve ilgili beklenen değerler ( $\mu$ 'ler), Şekil 2.8'de şemsiye şekilli alanla gösterilmektedir.



Şekil 2.8. Portföylerin beklenen değerleri ve riskleri (Yu, 2007)

Şekil 2.8'de tüm portföyler arasında  $S(\sigma, \mu)$ 'nin beklenen en yüksek getiriye sahip portföy ve  $E(\sigma, \mu)$ 'nin en küçük standart sapmaya sahip portföyler olduğu görülmektedir. SE eğrisi üzerinde yer alan portföyler, aynı beklenen değere (getiriye) ve aynı standart



sapmaya (riske) sahip portföyler arasında en küçük standart sapmaya (riske) sahip olması dolayısıyla etkin sınırı oluşturur.

Karar verici, beklenen getiri ile getirinin standart sapması (risk) arasındaki tercih dengelerini belirleyebilmektedir. Spesifik olarak, belirli bir beklenen getiriye ve standart sapmaya (risk) sahip olmak üzere, beklenen getirileri daha yüksek olan ancak aynı zamanda daha yüksek standart sapmaları (riskler) olan veya daha düşük standart sapmalara (risklere) sahip olan ancak aynı zamanda karar vericinin eşit olarak tercih edeceği daha düşük beklenen getirilere sahip birçok portföy vardır. Eşit derecede tercih edilen bu portföylerin  $(\sigma, \mu)$ 'ları, Şekil 2.8'de  $I_1, I_2$  ve  $I_3$  ile gösterilen eşit tercih eğrilerini oluşturur.

Bu eşit tercih eğrileri aşağıdaki özelliklere sahiptir:

- Birbirlerine zorunlu olarak paraleldirler, çünkü aksi takdirde iki eğrinin kesişimi, karar vericinin iki farklı tercih derecesine sahip bir  $(\sigma, \mu)$ 'yi temsil eder.
- Eşit beklenen değerlere sahip ancak farklı standart sapmalara veya risklere sahip iki portföy için, bir karar verici her zaman daha küçük standart sapma veya riske sahip portföyü tercih edecektir. Sonuç olarak, başka bir eşit tercih eğrisinin solundaki eşit tercih eğrisi daha yüksek bir tercih derecesine sahip olacaktır. Şekil 2.8'de,  $I_3, I_2$ 'den,  $I_2$  de  $I_1$ 'den daha yüksek bir tercih derecesine sahiptir.
- Çeşitlendirme yoluyla, eşit derecede tercih edilen iki portföyün doğrusal kombinasyonu, portföyler arasındaki korelasyona bağlı olarak eşit veya daha düşük riskli bir portföy ortaya çıkaracaktır. Bu nedenle, risksiz bir karar verici için, eşit tercih eğrisi, eğri üzerindeki iki noktanın doğrusal kombinasyonunun eğrinin üzerinde veya solunda olması nedeniyle zorunlu olarak dışbükeydir.

Bu özellikler göz önüne alındığında, Şekil 2.8'de O noktasında gösterildiği gibi, verimli sınırı tek bir teğet noktada kesen bir eşit tercih eğrisi olacaktır. Bu, karar vericiler için optimal portföyü temsil etmektedir (Yu, 2007).

### 2.2.3.3.2.1. Risk ölçüsü olarak standart sapma

Standart sapma, fonların riskini ölçmede kullanılan en yaygın yöntemdir (Doğanay, 2002). Standart sapma, bir fonun performansındaki oynaklığın istatistiksel bir ölçüsüdür. Bir dönem boyunca bir fonun toplam getirisinin aylık standart sapması, her ayın toplam getirisi ile dönem boyunca ortalama aylık toplam getirisi arasındaki farkın karesinin ortalamasının kareköküdür ve Denklem 2.2’de gösterilmektedir (Haslem, 2010).

$$\sigma(R_p) = \sqrt{\frac{\sum_{i=1}^T (R_{p_t} - \bar{R}_p)^2}{T}} \quad (2.2)$$

Denklemde  $\sigma(R_p)$  fon riskini,  $R_{p_t}$  fonun t dönemindeki getirisini,  $\bar{R}_p$  fonun ortalama dönemlik getirisini ve T dönem sayısını ifade etmektedir.

Bir portföyün standart sapması Denklem 2.3 yardımıyla hesaplanabilir (Guidolin ve Pedio, 2016).

$$\sigma(R_p) = \sqrt{\sum_{i=1}^n \sum_{j=1}^n w_i w_j Cov(R_i, R_j)} \quad (2.3)$$

Formülde  $R_p$  portföyün getirisini,  $\sigma(R_p)$  portföy riskini,  $w_i$  i yatırım fonunun portföydeki ağırlığını,  $w_j$  j yatırım fonunun portföydeki ağırlığını,  $R_i$  i yatırım fonunun getirisini,  $R_j$  j yatırım fonunun getirisini,  $Cov(R_i, R_j)$  i yatırım fonu ile j yatırım fonunun getirileri arasındaki kovaryansı temsil etmektedir.

### 2.2.3.3.2.2. Risk ölçüsü olarak beta

Beta, bir fonun fazla getirisinin, bir endeksin fazla getirilerindeki hareketlere duyarlılığının bir ölçüsüdür. Tasarım gereği, dizinin beta değeri 1,00’dir. Beta değeri 1,10 olan bir fon, diğer tüm faktörlerin sabit kaldığı varsayılarak, yukarı piyasalarda endeksten yüzde 10 daha yüksek ve aşağı piyasalarda yüzde 10 daha düşük getiri elde etme eğilimindedir. 0,85’lik bir beta, fonun yukarı piyasalarda endeksten yüzde 15 daha kötü

ve ařađı piyasalarda yzde 15 daha iyi performans gsterdiđini gsterir. Düşük beta, fonun düşük bir oynaklıđa sahip olduđu anlamına gelmez; daha ziyade düşük beta, yalnızca fonun endeksle ilgili riskinin düşük olduđu anlamına gelir (Haslem, 2010).

Beta, deđeri, bir bütün olarak pazar performansındaki bir deđişiklikten kaynaklanan performanstaki deđişikliđi temsil eden regresyon modelindeki katsayıdır. Pozitif beta katsayısına sahip yatırımlar, karşılaştırma ölçütü ile pozitif, negatif katsayılı olanlar ise negatif korelasyonludur. Beta, yatırımcıları, kıyas ölçütüne göre performansın işareti ve yönü ve kıyaslamadaki belirli bir deđişiklik için beklenebilecek getiri miktarı konusunda bilgilendirir. Sıfır beta, tüm geri dönüşün yönetici becerisi veya alfa tarafından oluşturulduđu anlamına gelir. 1,0 beta, tüm getirinin fon portföyünün karşılaştırma ölçütü ile ilişkilendirilmesinden geldiđini ve yöneticinin getirilere bir şey eklediđini veya hatta bunlardan hiçbir şey çıkarmadıđını ima eder. Bir yatırım yöneticisi tarafından kaldıraç ve açığa satış kullanımını genellikle alfaı artırır ve bir fon portföyünün betasını düşürür (Mirabile, 2016). Beta katsayısı Denklem 2.4 yardımıyla hesaplanmaktadır.

$$\beta_p = \frac{Cov(R_p, R_m)}{\sigma^2(R_m)} \quad (2.4)$$

Denklemde  $\beta_p$  portföyün sistematik riskini (betasını),  $Cov(R_p, R_m)$  portföyün getirisi ile pazar portföyü getirisi arasındaki kovaryansı ve son olarak  $\sigma^2(R_m)$  pazar portföyünün varyansını temsil etmektedir.

### 2.2.3.3.3. Portföy çeşitlendirme

Portföy yönetimindeki en önemli karar çeşitlendirmedir. Portföyün çeşitlendirilmesi, riski en aza indirmek için bir stratejidir. Çeşitlendirme, yatırımcıların risklerini dağıtabilmek adına tasarruflarını farklı menkul kıymetlerde deđerlendirmeleri olarak ifade edilebilir. Çeşitlendirmenin temelinde, portföyün toplam riskini düşürebilmek için negatif korelasyona sahip menkul kıymetlerin ya da finansal araçların portföye dahil edilmesi yer almaktadır. Aynı beklenen getiriye, aynı riske ve negatif korelasyona sahip iki menkul kıymetten oluşan portföyün beklenen getirisi aynı kalmakta, ancak riski

azalmaktadır. Bazı finansal araçların getirileri arasında korelasyon yoktur. Getirileri arasında korelasyon olmayan varlıklardan oluşan portföyün riski azalmakla birlikte, negatif korelasyona sahip menkul kıymetlerden oluşan portföyün riskinden daha az etkin olmakta, pozitif korelasyona sahip finansal araçlardan oluşan portföyün riskinden ise daha fazla etkin olmaktadır (Orçun, 2016b).

Profesör Markowitz'in önerdiği şekilde çeşitlendirme, belirli bir risk seviyesinde beklenen en yüksek getiriye sahip portföylerin oluşturulmasına yol açar. Bu tür portföylere verimli portföyler denir. Verimli portföyler oluşturmak için teori, işletmelerin varlık seçim davranışı hakkında bazı temel varsayımlarda bulunur. Varsayımlar aşağıdaki gibidir (Fabozzi vd., 2008):

- Varsayım 1: Bir yatırımcının kararını etkileyen yegâne iki parametre beklenen getiri ve varyanstır.
- Varsayım 2: Yatırımcılar riskten kaçınırlar. Yani, yatırımcılar aynı beklenen getiriye sahip ancak iki farklı riske sahip iki yatırımla karşı karşıya kaldıklarında, düşük riskli olanı tercih edeceklerdir.
- Varsayım 3: Tüm yatırımcılar, belirli bir risk seviyesinde beklenen en yüksek getiriyi elde etmeye çalışırlar.
- Varsayım 4: Tüm yatırımcılar, tüm riskli varlıklar için beklenen getiri, varyans ve kovaryanslarla ilgili aynı beklentilere sahiptir. Bu, homojen beklentiler varsayımı olarak adlandırılır.
- Varsayım 5: Tüm yatırımcıların ortak bir dönemlik yatırım ufku vardır.

#### **2.2.3.4. Portföy stratejisinin oluşturulması**

Müşterinin veya kurumun yatırım hedefleri ve yatırım politikası yönergeleri ile tutarlı bir portföy stratejisi seçmek, yatırım yönetimi sürecindeki diğer bir ana faaliyettir. Portföy stratejileri aktif veya pasif olarak sınıflandırılabilir. Aktif bir portföy stratejisi, basitçe geniş bir yelpazede çeşitlendirilmiş bir portföyden daha iyi bir performans aramak için mevcut bilgileri ve tahmin tekniklerini kullanır. Tüm aktif stratejiler için esas olan, bir varlık sınıfının performansını etkilediği bilinen faktörlere ilişkin beklentilerdir. Pasif bir

portföy stratejisi ise minimum beklenti girdisi içerir ve bunun yerine bazı piyasa endekslerinin performansına uyması için çeşitlendirmeye dayanır. Aslında, pasif bir strateji, piyasanın menkul kıymetler için ödenen fiyatta mevcut tüm bilgileri etkin bir şekilde yansıtacağını varsayar.

Aktif ve pasif yönetim hakkında yararlı bir düşünme şekli, yönetici tarafından gerçekleştirilen portföy oluşturma (satın alınacak ve satılacak hisse senetlerine karar verme), menkul kıymet ticareti ve portföy izleme faaliyeti açısından değerlendirilebilir. Genel olarak, aktif yöneticiler zamanlarının çoğunu portföy oluşturmaya ayırırlar. Aksine, yöneticiler pasif stratejilerle bu faaliyete daha az zaman ayırırlar. Yapılandırılmış bir portföy stratejisi, bir portföyün, ödenmesi gereken önceden belirlenmiş bazı yükümlülüklerin performansına ulaşmak için tasarlandığı stratejidir. Bu stratejiler, bir yatırım portföyünden alınan fonları, ödenmesi gereken gelecekteki borçlarla eşleştirmeye çalışırken sıklıkla kullanılır ve bu nedenle, yükümlülük odaklı stratejiler olarak adlandırılır (Fabozzi, 2009).

#### **2.2.3.5. Portföy yürütme**

Yürütme adımı portföy yöneticileri, analistlerin girdilerine dayalı olarak portföy kararlarını başlatır ve daha sonra ticaret masaları bu portföy uygulama kararlarını uygular (Xidonas vd., 2012) .

#### **2.2.3.6. Portföy revizyonu**

Portföy yönetiminde esas amaç, belirli bir risk seviyesinde maksimum getiriyi sağlamaktır. Bazı varlıklar dönem dönem portföyden çıkartılıp yeni varlıklar portföye dahil edilerek portföyün verimi artırılabilir. Burada yatırımcının risk ve getiri beklentileri, hedeflere ulaşmaktaki başarı, ekonomik ve piyasa koşulları takip edilerek, yatırımcının portföyü daha dinamik bir şekilde yönetilmeye çalışılır. Ayrıca yatırımcının ihtiyaçlarının değişmesi sonucu, hedefleri ve sınırlandırmaları da zaman içinde değişebilir. Bu da portföyde kapsamlı bir revizyona gidilmesine sebep olmaktadır (Koç, 2011).

### **2.2.3.7. Portföy performansının değerlendirilmesi ve portföy performanslarını değerlendirme yöntemleri**

Portföy yöneticilerinin performansının değerlendirilmesi hem yatırımcılar hem de araştırmacılar için önemli bir ilgi alanıdır. Yatırımcılar ve araştırmacılar, menkul kıymetlerin getirilerini tahmin etmeye yardımcı olan bilgileri toplama ve yorumlama yeteneğine sahip aktif yöneticilerin yüksek getiri sağlayıp sağlayamayacağına ilgi duymaktadır. Bununla birlikte, kurumsal portföy yöneticilerinin dünya çapında yarattığı artan işlem büyümesi, profesyonel yöneticilerin bir grup olarak yönettikleri portföylere değer katıp katmadıklarını bilmenin ne kadar önemli olduğunu vurgulamaktadır (Pendaraki ve Tsagarakis, 2016).

Gelişmiş piyasalarda rahatlıkla ulaşılabilen geriye dönük ve kapsamlı bilgiler sermaye piyasalarının bağımsız gözler tarafından incelenerek olası problem konularının ortaya çıkmasını sağlamaktadır. Bu sayede yatırımcılar konular hakkında daha donanımlı hale gelmektedirler. Bu çalışmalar, yatırım fonları için derinlemesine araştırma yapılması imkanı verdiği gibi fon yöneticilerinin de performanslarının sadece getiri açısından değil risk kategorileri açısından da tarafsızca incelenmesine olanak vermektedir (Öztürkkal, 2011).

Bir portföye yatırım yapan yatırımcının söz konusu portföyden nasıl bir performans elde edildiğini öğrenmek istemesi en doğal hakkıdır. Ayrıca bir yatırım yöneticisi de portföy performansını değerlendirerek güçlü ve zayıf yönlerini görebilir. Ayrıca portföy performansının ölçülmesinde sadece getiriye odaklanmak yerine risk ve getirinin bir arada ele alınması portföy yöneticisinin gerçek başarısını göstermesi açısından da son derece önemlidir (Günay, 2019).

Fon portföy performansının ölçülmesi; yatırımın başarısının belirlenmesi bakımından profesyonel portföy yöneticileri için olduğu kadar bireysel yatırımcılar için de önem taşımaktadır. Performansın ölçülmesinin amacı fon portföy getirisinin ne kadarının genel ekonomik piyasa hareketlerinden, ne kadarının da portföy yöneticisinin başarısından kaynaklandığının tespit edilmesidir (İltir, 2018).

Yatırım yönetimi firmaları birçok portföy yöneticisi istihdam etmektedir. Bir portföy yöneticisinin görevi, müşterilerin servet birikimlerini ve harcama ihtiyaçlarını karşılamalarına yardımcı olmaktır. Portföy yöneticileri yatırım performansının sağlanmasından, yatırım kararları almaktan ve yatırım sonuçlarından sorumlu kişilerdir. Yatırım kararları, ulaşılmaması istenen gelecek yatırım performansını elde etmek için varlık sınıflarının ağırlığının belirlenmesini içermektedir. Bir portföy yöneticisi, beklentileri karşılasa da karşılamasa da yatırım kararları sonucunda elde ettikleri yatırım performanslarından sorumlu tutulmaktadır. Hemen hemen bütün müşteriler, portföy yöneticileri tarafından değerlendirilen tasarruflarının değerinin en üst düzeye çıkarılmasını istemektedir. Performans, müşteri beklentilerini karşılamıyorsa bir noktada portföy yöneticisi işinden olma riski ile karşı karşıya kalacaktır. Ancak performans sonucu beklentileri aşıyorsa, müşteri taahhütlerinin seviyesi artabilir ve böylece portföy yöneticisinin bağlı olduğu kuruluş için daha yüksek yönetim ücretleri kazanımı sağlayabilir (Stewart vd., 2019).

Bazı yöneticilerin diğerlerinden daha iyi olduğu bulgusu, mükemmel verimli varlık piyasalarına sahip bir dünyada paradoksal olacaktır, ancak bu bilgi açısından verimli piyasaların olduğu bir dünyada tamamen doğaldır. Bir yatırım fonu yöneticisinin görevi, neredeyse verimli bir piyasada bilgi toplamak ve analiz etmekse, bazı yöneticilerin diğerlerinden daha iyi olduğu iddiası, bazı doktorların veya bazı ekonomistlerin diğerlerinden daha iyi olduğu iddiasından daha şaşırtıcı olmamalıdır (Chevalier ve Ellison, 1999).

Bu başlık altında, tez çalışmasında kullanılan dört ana yatırım fonu portföyü performans ölçüsü açıklanmaktadır.

#### **2.2.3.7.1. Jensen alfa**

Sermaye Varlıklarını Fiyatlandırma Modelini temel alan Jensen alfa, portföyün getirisinin, Sermaye Varlıklarını Fiyatlandırma Modeline göre finansal varlık piyasa doğrusu ile ifade edilen teorik getiriyi ne kadar aştığını ölçmekte ve Denklem 2.5'te görüldüğü gibi hesaplanmaktadır (Temizel ve Bayçelebi, 2016; Yücel, 2016).

$$R_{p,t} - R_{f,t} = \alpha_p + \beta_p [R_{m,t} - R_{f,t}] + e_{p,t} \quad (2.5)$$

Denklemden  $R_{p,t}$  portföyün t dönemindeki getirisini,  $R_{f,t}$  t dönemindeki risksiz faiz oranını,  $\alpha_p$  portföyün alfa katsayısını,  $\beta_p$  portföyün beta katsayısını,  $R_{m,t}$  t dönemindeki pazar getirisini ve son olarak  $e_{p,t}$  t dönemindeki portföyün hata payını ifade etmektedir.

Jensen alfa, portföy performansını tek bir değerle ölçmektedir. Jensen alfa terimi, portföy getirileri ile pazar getirileri arasında kurulan regresyon denkleminin sabit terimi olan alfa katsayısıdır (Korkmaz ve Uygurtürk, 2007a). Bu denklemde  $\alpha_j$  değeri (veya alfa), portföy yöneticisinin piyasa zamanlaması ve fon seçiminde veya her ikisinde de üstün mü yoksa aşağı mı olduğunu gösterir. Alfa, portföydeki getiri oranının ne kadarının, yöneticinin riske göre ayarlanmış ortalamasının üzerinde getiri elde etme kabiliyetiyle ilişkilendirilebileceğini temsil eder. Üst düzey bir yönetici önemli bir pozitif  $\alpha_a$ 'ye sahip olacak ve düşük düzeydeki yöneticinin getirileri  $\alpha_a$  için önemli bir negatif değere sahip olacaktır. Piyasayı temelde riske göre ayarlanmış bazda eşleştiren bir portföy yöneticisi, sıfırdan önemli ölçüde farklı olmayacak bir alfa değerine sahip olacaktır.

Portföy alfa iki farklı şekilde hesaplanabilir. İlk olarak, dönem-dönem alfa, Denklem 2.5 kullanılarak hesaplanabilir. Denklemde hata terimi sıfır olarak varsayılmıştır. Yani, denklem, alfayı bulmak için Denklem 2.6'da görüldüğü gibi yeniden düzenlenebilir.

$$\begin{aligned} R_{p,t} - R_{f,t} &= \alpha_p + \beta_p [R_{m,t} - R_{f,t}] + e_{p,t} \\ \alpha_p &= (R_{p,t} - R_{f,t}) - \beta_p [R_{m,t} - R_{f,t}] \end{aligned} \quad (2.6)$$

İkinci olarak, bir portföyün getirisi, risksiz oran ve piyasa getirisi hakkındaki zaman serisi verileri, basit bir doğrusal regresyon oluşturmak için birlikte kullanılabilir. Regresyondaki sabit veya kesişen terim, portföyün alfa değerinin tahminidir (Ranganatham ve Madhumathi, 2006).



Alfa, genellikle kıyas ölçütünün üzerindeki aktif veya fazla getiriyi tanımlamak için kullanılmaktadır. Bununla birlikte, alfanın gerçek tanımı, riske göre ayarlanmış aktif yönetimin fazla getirisidir. Alfa, portföyünki ile karşılaştırılabilir bir risk seviyesine sahip, pasif, yatırım yapılabilir bir kıyaslama üzerindeki getiridir. Bu, alfanın aşırı risk alma yoluyla değil, yalnızca portföy yöneticilerinin güvenlik seçimi gibi yatırım kararları yoluyla kattığı ek değeri yakalamasını sağlar. Jensen alfa, beta riski biçiminde portföy yöneticileri tarafından alınan riske göre alfayı ayarlamak için kullanılır (Lustig, 2013).

Alfanın amacı, bir fon yöneticisinin bir portföye göre nasıl değer kattığını veya azalttığını göstermektir, ancak doğruluğunda sınırlamalar vardır. Alfanın kullanışlılığı tamamen betanın doğruluğuna bağlıdır. Beta, kesin bir risk tanımı olarak kabul edilirse, pozitif bir alfa, iyi fon performansının kesin bir göstergesi olacaktır (Haslem, 2010).

#### **2.2.3.7.2. Sharpe Oranı**

Günümüzde yatırımcılar ve yatırım danışmanları, yatırım araçlarını birbirleriyle karşılaştırmak için çok sayıda performans ölçütüne erişebilmektedir. En iyi bilinen performans ölçütü, beklenen fazla yatırım getirisini fazla getirinin standart sapmasına bölen Sharpe oranıdır (Frahm ve Huber, 2019). Portföylerin performanslarını ölçmekte kullanılan çeşitli tek parametrelili risk/getiri ölçütlerinden en çok bilineni olan Sharpe oranı, farklı volatilitelerinde faaliyet gösteren fonların karşılaştırılmasına izin verdiği için faydalıdır. Birim risk başına ortalama fazla getiriyi temsil eder. Sharpe tarafından geliştirilen bu performans ölçütü Denklem 2.7’de görüldüğü gibi hesaplanmaktadır.

$$S_p = \frac{(E(R_p) - R_f)}{\sigma(R_p)} \quad (2.7)$$

Formülde  $S_p$  Sharpe oranını,  $E(R_p)$  portföyün beklenen getirisini,  $R_f$  risksiz faiz oranını,  $\sigma(R_p)$  ise toplam portföy riskini (portföy getirilerinin standart sapmasını) ifade etmektedir.

Bu performans ölçütü, yalnızca beta tarafından özetlenen sistematik riski dikkate almak yerine, getirilerin standart sapmasını kullanarak portföyün toplam riskini ölçmeyi amaçlamaktadır. Pay, portföyün risk primi olduğundan, bu ölçüt toplam risk birimi başına kazanılan risk primi getirisini gösterir. Bu nedenle, bu portföy performansı ölçütü portföyleri karşılaştırmak için sermaye piyasası doğrusunu kullanır (Reilly vd., 2010).

Portföy yöneticilerinin becerilerini ölçebilmek için onların portföylerinin Sharpe oranını pazarın Sharpe oranı ile karşılaştırmak gerekir. Daha yüksek Sharpe oranı yöneticinin başarısını gösterirken daha düşük Sharpe oranı yöneticinin başarısızlığını ortaya koymaktadır (Karan, 2020).

#### **2.2.3.7.3. Treynor Oranı**

Treynor oranı, temelde Sharpe oranı ile benzer özellikler göstermektedir. Treynor oranında, Sharpe oranından farklı olarak portföy riskini ölçmek için toplam risk göstergesi olan standart sapma yerine sistematik risk göstergesi olan beta katsayısı kullanılmaktadır. Treynor oranı, üstlenilen her bir birim sistematik risk karşılığında elde edilen ek getiriye ölçen orandır. Bundan dolayı incelemeye alınan portföylerin yüksek bir Treynor oranına sahip olması tercih edilir (Münyas, 2018). Treynor oranı Denklem 2.8’de görüldüğü gibi hesaplanmaktadır.

$$T_p = \frac{(E(R_p) - R_f)}{\beta_p} \quad (2.8)$$

Formülde  $T_p$  Treynor oranını,  $E(R_p)$  portföyün beklenen getirisini,  $R_f$  risksiz faiz oranını,  $\beta_p$  ise toplam portföyün sistematik riskini (betasını) ifade etmektedir.

#### **2.2.3.7.4. Enformasyon Oranı**

Hem Jensen alfa hem de Treynor oranı, hesaplamalarda fonun sistematik olmayan riskini göz önünde bulundurmamaktadır. Enformasyon oranı, Denklem 2.9’da görüldüğü gibi hesaplanarak bahsi geçen yöntemlerin ihmal ettiği sistematik olmayan riski de göz önünde bulundurmaktadır (Korkmaz ve Uygurtürk, 2008).

$$IR = \frac{\alpha_p}{\sigma_s} \quad (2.9)$$

Denklemden  $IR$  Enformasyon oranını,  $\alpha_a$  a portföyünün Jensen alfasını,  $\sigma_s$  ise portföyün sistematik olmayan riskinin karekökünü ifade etmektedir.

Enformasyon oranı, genellikle bir portföy yöneticisinin becerisinin ölçüsü olarak tanımlanmaktadır. Pozitif bir enformasyon oranı portföy yöneticisinin yüksek bir performans sergilediğini, negatif bir enformasyon oranı ise portföy yöneticisinin düşük bir performans sergilediğini göstermektedir. Kimi çalışmalarda ise enformasyon değerinin 0,5 olması portföy yöneticisinin iyi, 0,75 olması portföy yöneticisinin çok iyi ve 1 olması portföy yöneticisinin olağanüstü yüksek performans gösterdiği görüşü öne sürmektedir (Bacon, 2008).

### **2.3. Yatırım Fonu Kapanış Fiyatının Tahminine İlişkin Önceki Araştırmalar**

Chiang vd. (1996) makalelerinde, yatırım fonlarının yıl sonu net aktif değerlerini tahmin etmek için bir YSA modeli önermişlerdir. Yazarlar, YSA ile elde ettikleri tahmin sonuçlarını doğrusal regresyon analizi ve doğrusal olmayan regresyon analizi tahmin sonuçlarıyla karşılaştırmış ve sınırlı veri kullanılabilirliği olan durumlarda sinir ağlarının regresyon modellerinden önemli ölçüde daha iyi performans gösterdiği sonucuna varmıştır.

Ray ve Vina (2004) tarafından kaleme alınan çalışma, milli hasıla, faiz oranı, enflasyon, döviz kuru, para arzı, toplam hisse senedi piyasası gibi çeşitli değişkenlerin seçilen Hint yatırım fonlarının net varlık değerleri üzerindeki görece etkisini ortaya koymaya çalışmaktadır. Bu çalışmada YSA tekniği uygulanmış ve seçilen değişkenler temelinde yatırım fonu net varlık değerleri tahmin edilmeye çalışılmıştır. Bulgu, faiz oranı, para arzı, enflasyon oranı ve hisse senedi piyasası gibi belirli değişkenlerin söz konusu dönemde net varlık değeri hareketinde önemli bir etkiye sahip olduğunu, diğer değişkenlerin ise yatırım fonu getirileri üzerinde çok önemsiz bir etkiye sahip olduğunu göstermektedir.

Han-Sen vd. (2007) tarafından gerçekleştirilen çalışmanın amacı, tek uluslu özsermaye fonlarının net varlık değerini tahmin etmek için Gray, Radyal Temel Fonksiyonlu (RBF) sinir ağı (RBFNN) ve Gray-RBFNN modellerini uygulamaktır. Üç algoritmanın tahmin performansları, üç tek uluslu hisse senedi fonu, JF Japonya Yeni Nesil Fonu, JF Tayvan Fonu ve JPM Yeni Amerika Güvence Fonu verileri kullanılarak karşılaştırılmıştır. Performans ölçütleri karşılaştırıldığında en iyi performansı gösteren algoritma Gray-RBFNN modeli olmuştur.

Lu vd. (2008) bildirimlerinde, yatırım fonu performans tahmini için destek vektör regresyonu modelinden ve geri yayılım ağ modelinden faydalanmışlardır. Çalışmada girdi olarak tüketici fiyat endeksi (TÜFE), gayri safi milli hasıla (GSMH), işsizlik oranı, swap faiz oranı, döviz kuru, TAİEX değişim oranı, önceki dönem (ay) net fon değeri, Treynor endeksi, Sharpe endeksi, Beta değeri, Hareketli ortalama yakınsaması / ıraksaması (MACD), Sapma oranı (BIAS), ortalama hacim, Relatif güç endeksi (RSI) ve Williams %R göstergesi kullanılmıştır. Çıktı olarak da yatırım fonu performansını belirlemişlerdir.

Hongcheng vd. (2010) çalışmalarında, yatırım fonunun net aktif değerini tahmin etmek için bir geri yayılım sinir ağı önermişlerdir. HUAXIACHENGZHANG yatırım fonu üzerine yapılan ampirik analiz, sinir ağı tahmin modelinin iyi doğrusal olmayan yansıtma yeteneğine, öğrenme yeteneğine ve tahmin hassasiyetine sahip olduğunu göstermektedir.

Ben Belgacem ve Hellara (2011) tarafından kaleme alınan makalenin amacı, Tunus öz sermaye yatırım fonlarının performansını açıklamak için geçmiş performans, fon büyüklüğü, yönetim ücretleri, fon yaşı, net varlık değeri ve fon büyümesi gibi iyi bilinen fon özelliklerinin incelenmesidir. Yazarlar bu amaç doğrultusunda çalışmalarında gelişmiş dinamik panel veri yaklaşımını kullanmışlardır. Yazarlar, hangi performans ölçüsünün kullanıldığına bakılmaksızın, geçmiş performansın ve fon büyüklüğünün tüm fon kategorileri için gelecekteki performans üzerinde olumlu ve önemli bir etkiye sahip olduğunu bulmuşlardır.

Akel ve Karacameydan (2012) makalelerinde Türkiye'deki yatırım fonlarının net varlık değerlerinin tahminini YSA ve regresyon modeli yardımıyla gerçekleştirmiştir. Çalışmada, net varlık değerlerinin tahmin edilmesinde aktif tahvilin faiz oranı, dolar kuru, toptan eşya fiyat endeksi, İMKB 100 endeksi, para arzı tutarı ve sanayi üretim endeksi gibi altı makro ekonomik girdiden faydalanılmıştır. Gerçekleştirilen analizlerin sonunda, yatırım fonu net varlık değerlerinin tahmininde YSA modelinin regresyon modeline kıyasla daha iyi sonuçlar verdiği ve tahmin hatalarının oldukça düşük olduğu çıkarımı yapılmıştır.

Priyadarshini ve Babu (2012) eserlerinde, Hindistan'da işlem gören Sahara yatırım fonunun net aktif değerini tahmin etmek amacıyla Çoklu Regresyon Analizi ve YSA'dan faydalanmışlardır. Kullanılan yöntemler yardımıyla standart istatistiksel performans ölçütleri olan MAE, MSE, RMSE, MAPE ve MPE değerleri elde edilmiş ve bulgular yardımıyla yatırım fonunun net aktif değerini tahmin etmede YSA'nın Çoklu Regresyon Analizine kıyasla daha başarılı olduğu sonucuna varılmıştır.

Huang ve Leu (2014) çalışmalarında önce performans ölçütleri, aylık getiri oranı ve veri zarflama analizini kullanarak piyasadaki hisse senedi bazlı yatırım fonları portföyü seçmişler, sonrasında ise portföydeki her bir yatırım fonunun net varlık değerini tahmin etmek için meyve sineği optimizasyon algoritması tarafından optimize edilen genel regresyon sinir ağını kullanmışlardır. Elde edilen sonuçlar, diğer kombinasyonlarla karşılaştırıldığında, portföy seçimi için Sharpe oranı kullanımının ve net varlık değeri tahmini için meyve sineği optimizasyon algoritması ile optimize edilmiş genel regresyon sinir ağı kombinasyonunun, yatırım fonu portföy yatırımı için en iyi kümülatif getiri oranını sunduğunu göstermektedir.

Anish ve Majhi (2015a) çalışmalarında, Hint yatırım fonlarının net aktif değerini tahmin etmek amacıyla RBF ve Fonksiyonel Bağlantılı Yapay Sinir Ağı (FLANN) gibi tek sinir ağı modellerinden daha üstün performans gösteren bir ensemble tahmin modeli geliştirmişlerdir. Yazarlar tarafından önerilen modelin tahmin performansını değerlendirmek için, önerilen modelden elde edilen MAPE ve RMSE değerleriyle tekli modellerden elde edilen MAPE ve RMSE değerleri karşılaştırılmıştır. Önerilen model,

her bir modele kıyasla MAPE ve RMSE değerleri açısından gelişmiş performans göstermektedir.

Anish ve Majhi (2015b) tarafından yapılan çalışmada doğrusal olmayan girdileri içeren FLANN tabanlı bir tahmin modeli geliştirilmiş ve net aktif değerinin doğru bir şekilde tahmin edilmesi amaçlanmıştır. Elde edilen bulgular, önerilen tahmin modelinin etkili ve yatırım fonu net aktif değerlerinin tahmininde uygulanabilir olduğunu göstermektedir.

Narula vd. (2015) çalışmalarında bir yatırım fonunun net aktif değerini tahmin etmek amacıyla FLANN, Çok Katmanlı Algılayıcı (MLP) ve RBF ağlarından faydalanmıştır. 15 gün için net aktif değer tahmini için FLANN en iyi performans gösterirken, 7 günlük net aktif değer tahmini için RBF en iyi performansı göstermiştir.

Priyadarshini (2015) makalesinde Sahara yatırım fonunun net varlık değerini tahminini yapmak için ARIMA ve YSA modellerinden faydalanmıştır. Yazar, modellerin doğruluğunu değerlendirmek için MAE, MSE, RMSE, MAPE ve MPE performans ölçütlerini karşılaştırmıştır. Burada bahsi geçen tüm hata tahminlerinde YSA modelinin, ARIMA modeline kıyasla daha iyi performans gösterdiği tespit edilmiştir.

Anish ve Majhi (2016) makalelerinde Hint yatırım fonlarının net varlık değerini tahmini için daha az hesaplama yükü ve hızlı tahmin kabiliyeti içeren bir FLANN önermişlerdir. Bahsi geçen YSA modeli ile gerçekleştirilen tahminlere ilişkin performans ölçütleri olan RMSE ve MAPE değerleri, çok katmanlı yapay sinir ağı (MLANN) ve FLANN performans ölçütü değerleriyle karşılaştırılmıştır. Karşılaştırma sonucunda önerilen modelin MLANN ve FLANN'den daha üstün performans gösterdiği tespit edilmiştir.

Aytekin (2018) makalesinde, Türkiye'deki portföy yöneticilerinin, özellikle de sermaye ve katılım yatırım fonu yöneticileri ile bireysel emeklilik fonu yöneticilerinin, getiri performansını etkileyen orta ve uzun vadeli faktörleri belirlemeye çalışmıştır. Bu amaçla, hisse senedi yatırım fonu yöneten portföy yöneticilerinin getiri performansının belirleyicisi olduğu düşünülen Sharpe oranı, Treynor oranı, Jensen alfası, yukarı yönlü tutma oranı ve aşağı yönlü tutma oranı değişkenleri ile çoklu doğrusal regresyon modeli

oluşturulmuştur. Analizler 2015 (366 gün), 2016 (366 gün) ve 2017 (253 gün) yılları için ayrı ayrı ve 2015-2017 yıllarının tamamı için (986 gün) gerçekleştirilmiştir. 2015, 2016 ve 2017 yılları ile 2015-2017 dönemi için Jensen alfa bağımlı değişkeninin fon portföy yöneticisinin getirisinin üzerinde en etkili faktör olduğu tespit edilmiştir.

Hota vd. (2018) bildirimlerinde Hindistan yatırım fonlarından ikisi için 1 günlük, 3 günlük, 5 günlük ve 7 günlük net varlık değerini tahmin etmek için Yunus Sürüsü Algoritması (DSA) ile hibritleştirilmiş Aşırı Öğrenme Makinesi (ELM) modelini önermişlerdir. Net varlık değeri, mevcut net varlık değeri, ortalama, standart sapma, basıklık ve çarpıklık değerleri girdileri ile tahmin edilmektedir. DSA-ELM modelinin tahmin performansı temel ELM makinesi performansı ile karşılaştırılmış ve sonuçlar DSA-ELM modelinin temel ELM modelinden daha üstün olduğunu göstermektedir.

Rani ve Chandar (2018) çalışmalarında girdi olarak ülkelerin makroekonomik değişkenleri olan enflasyon oranı, tüketici fiyat endeksi, hazine faiz oranı, döviz kuru, işsizlik oranı, M1 para arzı ve M2 para arzı değişkenlerini kullanarak YSA yardımıyla Hindistan yatırım fonlarının ikisinin net varlık değerini tahmin etmişlerdir. Analizden, en iyi ve en hızlı eğitim algoritmasının Levenberg-Marquardt (LM) olduğu tespit edilmiştir.

Aytekin ve Güler Özçalık (2019) tarafından ele alınan çalışmada yatırım fonu portföy yöneticilerinin getiri performanslarına kısa ve uzun vadede etki eden faktörler belirlenmeye çalışılmıştır. Bu amaçla 2014, 2015, 2016, 2017 ve 2018 yıllarında ayrı ayrı, 2014-2018 döneminde sürekli olarak yatırım fonu yöneten portföy yöneticilerinin getiri performanslarının belirleyicileri olacağı düşünülen Standart sapma, Sharpe oranı, Treynor oranı, Jensen alfası, Beta, yukarı yönlü tutma oranı ve aşağı yönlü tutma oranı değişkenlerinin geçmiş tarihli hareketleri ile yönetici getirileri incelenmiştir. Yönetici getirileri, büyükten küçüğe doğru yapılan sıralamayla kartillere ayrılmış ve diğer değişkenlerin beklenen değerlerine göre ayrı ayrı yönetici getirisi ile olan birliktelikleri tespit edilmiştir. Yapılan frekans analizi sonucunda 2015 yılı hariç diğer dönemlerde, yönetici getirisi ile en yüksek birliktelik oranlarının Jensen alfası ve yukarı yönlü tutma oranı tarafından sağlandığı görülmüştür.

Hota vd. (2020) makalelerinde Hindistan yatırım fonlarından ikisi için 1 günlük, 3 günlük, 7günlük, 15 günlük ve 30 günlük net varlık değerini tahmin etmek için Fil Sürüsü Optimizasyonu (EHO) algoritması ile hibritleştirilmiş YSA modelini önermişlerdir. Net varlık değeri, mevcut net varlık değeri, ortalama, standart sapma, basıklık ve çarpıklık değerleri girdileri ile tahmin edilmektedir. ANN-EHO modelinin tahmin performansı, temel YSA modelinin, Genetik Algoritma (GA) ile hibritleştirilmiş YSA modelinin (ANN-GA), Parçacık Sürüsü Optimizasyonu (PSO) ile hibritleştirilmiş YSA modelinin (ANN-PSO) ve Diferansiyel Evrim (DE) ile hibritleştirilmiş YSA modelinin (ANN-DE) tahmin performansı ile karşılaştırılmıştır. Sonuçlar, ANN-EHO modelinin diğer dört modelden daha üstün olduğunu göstermektedir.

Koudjonou ve Rout (2020) eserlerinde Hindistan yatırım fonlarının beşi için net varlık değerini tahmin etmek amacıyla Uzun Kısa Süreli Bellek (LSTM) ve Geçitlendirilmiş Özyinelemeli Birimler (GRU) modelleri geliştirmişlerdir. Yazarlar net varlık değerleri ile tek zaman adımı ve tek özellik, çoklu zaman adımları ve tek özellik, son olarak da çoklu zaman adımları ve çoklu özellikler gibi üç veri hazırlama yöntemiyle girdileri oluşturup net varlık değerinin tahminini doğru bir şekilde elde etmeye çalışmışlardır. Yapılan analizler sonucunda GRU modeli ve çoklu zaman adımları ve çoklu özellikler veri hazırlama yöntemiyle net aktif değerinin tahminin en iyi performansı gösterdiği sonucuna varılmıştır.

Hota vd. (2021a) çalışmalarında bir Hint yatırım fonunun 1 günlük, 3 günlük, 7 günlük ve 15 günlük net varlık değeri tahminini yapmak için MLP, ELM ve FLANN gibi sinir ağı modellerinin farklı varyantları kullanılmıştır. Net varlık değeri, mevcut net varlık değeri, ortalama, standart sapma, basıklık ve çarpıklık değerleri girdileri ile tahmin edilmektedir. Net varlık değeri verileri, 80:20 oranında eğitim ve test verilerine bölünmüştür ve bu modellerin performansı RMSE ve MAPE değerleri kullanılarak değerlendirilmiştir. Deneysel sonuçlar, bu iki Hint yatırım fonu için net varlık değerlerini tahmin etmede ELM'nin diğer iki modelden daha iyi performans gösterdiğini göstermektedir.



Hota vd. (2021b) çalışmalarında iki Hint yatırım fonunun 1 günlük ve 5 günlük net varlık değeri tahmini için FLANN modeli kullanmışlar ve FLANN modelinin ağırlıklarını ateşböceği algoritması kullanarak optimize etmişlerdir. Elde edilen sonuçlar incelendiğinde önerilen modelin tahminde temel FLANN modelinden daha başarılı olduğu görülmektedir.

Majhi vd. (2021) yatırım fonu net aktif değerinin tahmini için geliştirdikleri geri yayılım tabanlı hibrit sinir ağının tahmin performansını, Uyarlanabilir hareketli ortalama tabanlı tahmin modeli, Uyarlanabilir otomatik regresif hareketli ortalama tabanlı tahmin modeli ve FLANN modellerinin performanslarıyla karşılaştırmışlar ve geliştirdikleri hibrit modelin daha iyi tahmin doğruluğuna sahip olduğu sonucuna ulaşmışlardır.

Wu vd. (2021) makalelerinde hedge fonların gelecekteki getirilerini tahmin etmek ve bunu yüksek getiri potansiyeli olan hedge fonlarını seçmek amacıyla kullanmak için makine öğrenmesi algoritmalarından Küçük Mutlak Küçülme ve Seçim Operatörü, Rastgele Orman, Gradyan Artırma ile Derin Sinir Ağları yöntemlerinden faydalanmışlardır. Tahmin modeli, her bir fonun geçmiş getirilerinden türetilen, son getirilerin fon bilgilerini, risk ölçümlerini, yönetici becerisini ve operasyonel riskleri kapsayan girdi özellikleriyle donatılmıştır.

### 3. MATERYAL ve YÖNTEM

#### 3.1. Materyal

Çalışmaya ait veri seti, Borsa İstanbul bünyesinde mevcut piyasalarda gerçekleşen; pay, borçlanma araçları, yurt dışı sermaye piyasası araçları, türev araçlar ve kıymetli madenler ile ilgili işlemlerin nakit ve menkul kıymet takasını sonuçlandırmak üzere yetkilendirilmiş merkezi takas kuruluşu olan İstanbul Takas ve Saklama Bankası A.Ş. (Takasbank)'ın bir iştiraki olan Türkiye Elektronik Fon Alım Satım Platformu (TEFAS)'tan elde edilmiştir (Takasbank, 2021). TEFAS, tüm fonları tek bir sistem üzerinden karşılaştırma ve tek bir yatırım hesabıyla piyasadaki tüm fonlara ulaşma imkanı sağlayan elektronik fon platformudur (TEFAS, 2021c). TEFAS elektronik fon platformundan 2017-2021/6 yılları arasında işlem gören menkul kıymet yatırım fonlarına ilişkin günlük genel bilgiler ve portföy dağılımı sayısal bilgileri toplanmıştır. Günlük genel bilgiler içerisinde tarih, fon kodu, fon adı, fiyat, tedavüldeki pay sayısı, kişi sayısı ve fon toplam değeri verileri yer almaktadır. Portföy dağılımı sayısal bilgileri içerisinde ise tarih, fon kodu ve fon adının yanı sıra ilgili fonun portföy dağılımını oluşturan hisse senedi, devlet tahvili, hazine bonusu, döviz kamu iç borçlanma araçları, döviz ödemeli bono, döviz ödemeli tahvil, finansman bonusu, özel sektör tahvili, banka bonusu, varlığa dayalı menkul kıymetler, gayri menkul sertifikası, eurobonds, kamu dış borçlanma araçları, özel sektör dış borçlanma araçları, Takasbank para piyasası, kamu kira sertifikaları, kamu kira sertifikaları (TL), kamu kira sertifikaları (döviz), özel sektör kira sertifikaları, kamu yurt dışı kira sertifikaları, özel sektör yurt dışı kira sertifikaları, vadeli mevduat, mevduat (TL), mevduat (döviz), mevduat (altın), katılım hesabı, katılma hesabı (TL), katılma hesabı (döviz), katılma hesabı (altın), repo, ters-repo, kıymetli madenler, kıymetli madenler cinsinden borsa yatırım fonları, kıymetli madenler kamu borçlanma araçları, kıymetli madenler kamu kira sertifikaları, yabancı menkul kıymet, yabancı borçlanma aracı, yabancı kamu borçlanma araçları, yabancı özel sektör borçlanma araçları, yabancı hisse senedi, yabancı borsa yatırım fonları, fon katılma belgesi, yatırım fonları katılma payları, borsa yatırım fonları katılma payları, gayrimenkul yatırım fon katılma payları, girişim sermayesi yatırım fon katılma payları, türev araçları, vadeli işlemler nakit teminatları ve diğer gibi kalemlerin yüzdeler ağırlıkları yer almaktadır (TEFAS, 2021b).

Elde edilen veri seti, 641 menkul kıymet yatırım fonu için 1128 iş günlük bir zaman serisinden oluşmaktadır. 1128 iş günlük veri incelendiğinde, herhangi bir günde en fazla sayıda portföy kalemine dağılan menkul kıymet yatırım fonları Deniz Portföy Birinci Değişken Fon (DBP), HSBC Portföy Çoklu Varlık Birinci Değişken Fon (HPO) ve TEB Portföy Mutlak Getiri Hedefli Değişken Fon (TE3)'dur. DBP 45 gün, HPO 2 gün, TE3 ise 4 gün 16 farklı portföy kalemine dağılmıştır. Bu nedenle ilk analiz, en çok portföy kalemine dağılan menkul kıymet yatırım fonlarından biri olan DBP için yapılmıştır. Deniz Portföy Birinci Değişken Fon, dengeli portföy yapısıyla orta ve uzun vadede istikrarlı yüksek getiri elde etmek isteyen yatırımcılara yönelik bir fondur. Fonun yatırım stratejisine göre fon ağırlıklı olarak yerli ve yabancı kamu ve özel sektör borçlanma araçlarına yatırım yapmaktadır. Diğer yandan Türkiye ve global finansal piyasalardaki gelişmeler yakından takip edilerek fon portföyünün diğer para ve sermaye piyasası araçlarıyla çeşitlendirilip aktif bir şekilde yönetilmesi amaçlanmaktadır (KAP, 2021).

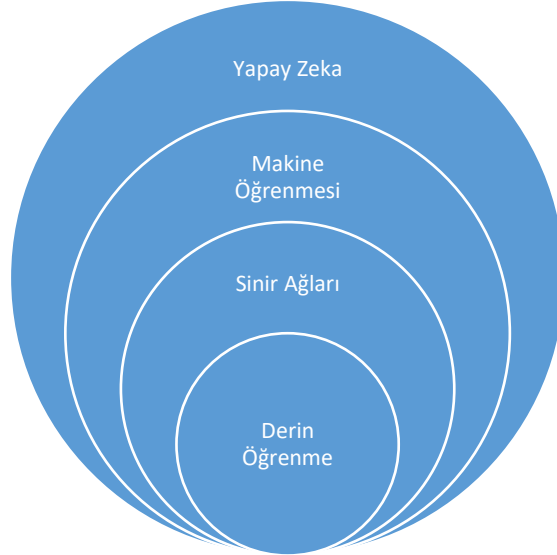
İkinci bir analiz ise en fazla işlem hacmine sahip fon için gerçekleştirilmiştir. Fon bazlı işlem hacmi raporuna göre 2017-2021/6 yılları arasında ilk ona giren fonlar Çizelge 3.1'de gösterilmiştir. Çizelgeye göre en fazla işlem hacmine sahip olan fon İstanbul Portföy Kısa Vadeli Borçlanma Araçları Fonudur ve IST kısaltmasıyla gösterilmektedir. Fon, kısa vadeli yatırım hedefiyle hareket eden, devlet tarafından ihraç edilen enstrümanlara yatırım yapmayı isteyen, düşük risk profilinde yatırımı tercih eden, faiz geliri ve istikrarlı fon getirisi arayışında olan yatırımcılar için uygundur. Fon ayrıca piyasalarda belirsizlik ortamında defansif davranmak isteyen katılımcılar için de bekleme döneminde kullanılacak bir enstrüman niteliğindedir. Fonun yatırım stratejisine göre yatırım yapılacak sermaye piyasası araçlarının seçiminde nakde dönüşümü kolay ve az riskli olanlar tercih edilmektedir (İstanbulPortföy, 2021).

**Çizelge 3.1.** 2017-2021/6 yılları arasında en yüksek işlem hacmine sahip ilk 10 fon tipi (TEFAS, 2021a)

Fon Ünvanı	İşlem Hacmi (TL)
İstanbul Portföy Kısa Vadeli Borçlanma Araçları Fonu	21 222 238 761
Garanti Portföy Birinci Değişken Fon	18 817 393 157
Fiba Portföy Para Piyasası Fonu	16 868 092 859
Ak Portföy Özel Sektör Borçlanma Araçları Fonu	10 503 930 529
Ak Portföy Birinci Fon Sepeti Fonu	9 341 956 990
Azimet Portföy Para Piyasası Fonu	9 157 192 994
HSBC Portföy Çoklu Varlık Birinci Değişken Fon	9 108 707 000
Ak Portföy Yeni Teknolojiler Yabancı Hisse Senedi	6 764 297 972
Yapı Kredi Portföy İkinci Fon Sepeti Fonu	5 827 344 517
Teb Portföy Mutlak Getiri Hedefli Değişken Fon	5 575 467 342

### 3.2. Yöntem

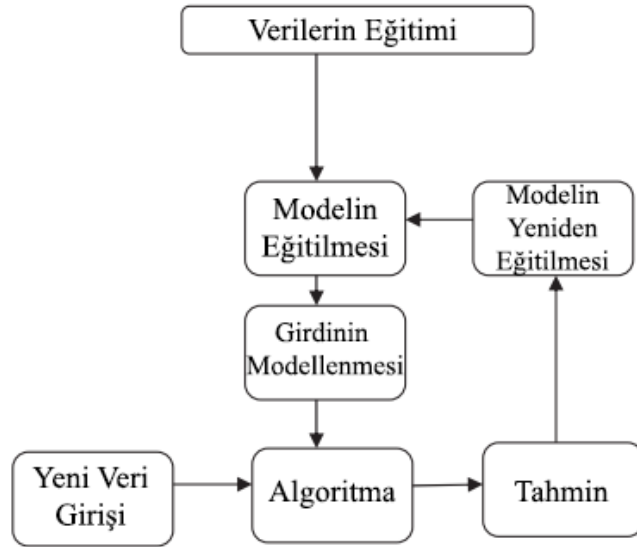
Yapay zekâ, normalde insanlar tarafından gerçekleştirilen entelektüel görevlerin otomatikleştirilmesi çabası olarak tanımlanmaktadır. Şekil 3.1'deki Venn diyagramında görüldüğü üzere yapay zekâ geniş bir alandır ve makine öğrenmesini, sinir ağlarını ve derin öğrenmeyi kapsamaktadır (Cai vd., 2020).



**Şekil 3.1.** Yapay zekâ, makine öğrenmesi, sinir ağları ve derin öğrenme arasındaki ilişki (Cai vd., 2020)

Makine öğrenmesi, yapay zekanın bir alt kümesidir ve makinelere açık programlama olmadan öğrenme yeteneği sağlamayı amaçlamaktadır. Buradaki temel yaklaşım, bu tür makinelerin (veya bilgisayar programlarının) bir kez inşa edildikten sonra, yeni verilere maruz kaldıklarında gelişip uyum sağlayabilmeleridir. Bu yaklaşımın altında yatan ana fikir, bir makinenin deneyimlerinden genelleme yapabileceği fikridir. Bu yaklaşıma göre bir makineye bir kez bir dizi eğitim örneği verildiğinde, bu makineler yeni vakalara yeterli doğrulukla karar verebilecek genelleştirilmiş bir model oluşturabilmelidirler (Amaratunga, 2021).

Makine öğrenmesi, matematiksel ve istatistiksel yöntemler kullanarak mevcut verilerden çıkarımlar yapan, bu çıkarımlarla bilinmeyene dair tahminlerde bulunan yöntemdir (Çağlayan Akay, 2020). Şekil 3.2, makine öğrenmesinin çalışma modelini temsil etmektedir.



**Şekil 3.2.** Makine öğrenmesi çalışma modeli (Koul, 2021)

Makine öğrenmesi algoritmaları aşağıdaki şekilde kategorize edilmiştir:

- Denetimli Öğrenme: Makine öğrenmesi yaklaşımlarının tipik olarak üç ana yönü vardır. Bunlar, girdi verileri, yani algoritmaya sağlanan deneyim; tahmine dayalı bir model ve tahminlerin kendileridir. Girdi verileri, ilgili nesne özelliklerinin nicel ölçümlerinin veya gözlemlerinin bir koleksiyonu olarak düşünülebilir. Bu

veri koleksiyonu genellikle eğitim verileri olarak adlandırılır ve yeni (görülmeyen) verilerden yapılacak tahminlerin temeli olacak modelleri eğitmek için kullanılır. Bu, esasen algoritmanın öğrendiği deneyimdir. Eğitim verileri, bir kategori gibi istenen çıktıyla birlikte bir gözlem veya örnek şeklinde düşünülebilir. Eğitim verileri için, her örneklem için bir etiket varsa ve bu verilerin tümü bir tahmin modelini eğitmek için kullanılıyorsa, bu bir denetimli öğrenme tekniği olarak kabul edilir. Denetimli öğrenme, daha önce görülmemiş örnekleri sınıflandırma olarak adlandırılan önceden belirlenmiş kategorilere atamak için bir model eğitmek için kullanılabilir. Alternatif olarak, denetimli öğrenme bir süreklilik boyunca bir değer atamak için kullanıldığında, buna regresyon denir (Mavaddat vd., 2020).

- **Denetimsiz Öğrenme:** Denetimli öğrenmenin aksine, etiketlenmemiş veriler denetimsiz öğrenmede kullanılmaktadır. Denetimsiz öğrenmede, veri setlerinin herhangi bir etikete sahip olması gerekmez, veri kalıbı bilinmez ve etiketlenmemiş verilerdeki gizli kalıplar bulunmaya çalışılır. Denetimsiz öğrenme, veri etiketi yaklaşımının zayıf olduğu durumlarda kullanışlıdır. Burada makinenin görevi, önceden herhangi bir veri eğitimi almadan sıralanmamış bilgileri benzerliklere, modellere ve farklılıklara göre gruplamaktır. Denetimli öğrenmenin aksine makineye eğitim verilmez. Bu nedenle makine, etiketsiz verilerdeki gizli yapıyı kendi başına bulmakla yükümlüdür. Denetimsiz öğrenme kümeleme ve boyutsallık azaltma olmak üzere iki algoritma kategorisine ayrılmıştır (Mittal ve Hasija, 2020; Saha vd., 2020; Thiyagarajan, 2020). Kümeleme görevi sınıflandırmaya çok benzemektedir, ancak burada sınıflar bilinmemekte ve girdiler algılanan benzerliklerine göre gruplandırılmaktadır. Boyut azaltma ise aynı zamanda genelleme olarak da bilinir. Boyut azaltma, birden çok örnekte ortak ve en önemli özellikleri arama görevini gerçekleştirmektedir (Virmani vd., 2020).
- **Yarı Denetimli Öğrenme:** Yarı denetimli öğrenme, eğitim için hem etiketlenmiş hem de etiketlenmemiş verileri kullandığından denetimli ve denetimsiz öğrenme arasında bir yere düşmektedir. Bu öğrenme yönteminde tipik olarak az miktarda etiketli veri ve büyük miktarda etiketlenmemiş veri işleme alınmaktadır. Bu

yöntemi kullanan sistemler, öğrenme doğruluğunu önemli ölçüde artırabilmektedir (Akshaya M. ve Ganapathi, 2020).

- Pekiştirmeli Öğrenme: Pekiştirmeli öğrenme, sisteme ne zaman iyi ve ne zaman kötü olduğunu söyleyen bir ödül sinyali sağlayarak çalışmaktadır. Zamanla, sistem deneyler yapar ve deneme yanılma yoluyla beklenen ödülünü en üst düzeye çıkaracak bir politika keşfeder (Mitchell, 2021). Pekiştirmeli öğrenme, hangi eylemin en büyük ödülü sağladığını belirlemek için deneme yanılma yoluyla öğrenmeye çalışan bir yöntemdir. Pekiştirmeli öğrenme, aracı (karar verici veya öğrenci), çevre (aracının etkileşime girdiği şey) ve eylemler (aracının gerçekleştirebileceği eylemler) olmak üzere üç bileşene sahiptir (Quinto, 2020).

Makine öğrenmesi modellerini yürütmek için kullanılan programlama dilleri aşağıda sıralanmıştır. Tez çalışmasında belirtilen bu programlama dillerinden biri olan Matlab'dan faydalanılmıştır (Kumar ve Makkar, 2020).

- Matlab: Matlab, MathWorks tarafından geliştirilen ve analiz ve tasarım ortamını tek bir masaüstünde birleştiren bir programlama dilidir. Esas olarak matrislerde ve dizilerde depolanan veriler üzerinde çalışılan ve sayısal hesaplama kolaylığı ve bir araştırma topluluğu sağlayan çok paradigmatlı bir ortamdır. Matlab, veri işleme, çizim fonksiyonları, algoritma uygulama ve arayüz yönetimi kolaylığı sağlamakta ve diğer dillerde (C, C++, Java, C #) yazılmış programların kolayca anlaşılmasını sağlamaktadır.
- Python: Python, çevrimiçi olarak kullanılabilen açık kaynaklı bir yazılımdır. Python, programlama için çoğunlukla öğrenciler, geliştiriciler ve araştırmacılar tarafından benimsenen ve çok sayıda paket ve kütüphanenin yerleşik olduğu bir dildir. Python'da sınıflandırma, regresyon, kümeleme ve ilişkilendirme gibi makine öğrenmesi teknikleri uygulanabilmektedir. Bunun yanı sıra makine öğrenmesi algoritmalarının verimliliğini artırmak için optimizasyon yapılması imkanını da sağlamaktadır.
- R: R, ücretsiz ve açık kaynaklı bir istatistiksel programlama dilidir. Aynı zamanda çok sayıda makine öğrenmesi paketi ve görselleştirme aracına sahiptir. Makine öğrenmesi modellerinin çoğunu programlamak için kullanılan kütüphaneleri de destekler.

- Weka: Weka, makine öğrenmesi algoritmalarını yürütmek için geliştirilmiş açık kaynaklı bir yazılımdır. Weka, sınıflandırma, regresyon, ilişkilendirme ve kümeleme için çeşitli araçlar içermektedir.

### 3.2.1. Yapay sinir ağları

Hemen hemen tüm süreçler yüksek düzeyde karmaşıklık içermektedir. Bununla birlikte bu süreçler genellikle büyük miktarda veri üretmektedir. Bu veriler önemli bilgileri elde etmek için ilişkilendirilebilir. Değişkenler veya varlıklar arasındaki ilişkileri anlamaya çalışmak zorlu bir iş olmasına karşın bu amaç için, her biri farklı karmaşıklık ve doğruluk düzeylerine sahip çeşitli teknikler mevcuttur. Bu bağlamda YSA öne çıkan bir tekniktir (Martins vd., 2011).

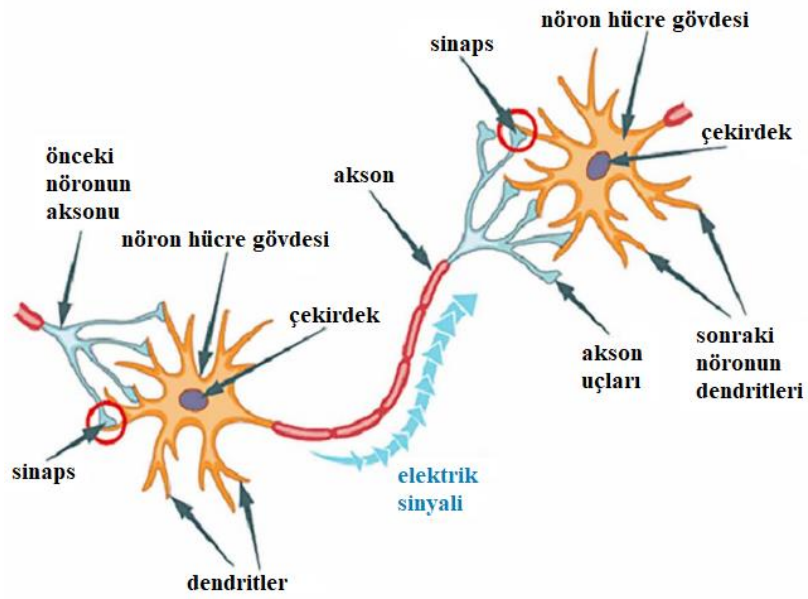
YSA'nın ortaya çıkışı, nörobiyologlar tarafından beyin çalışma mekanizmasının araştırılmasına dayanmaktadır. YSA, ağ topolojisi bilgisine göre biyolojik merkezi sinir sistemi bilgilerinin işleme şeklini özetleyen ve simüle eden matematiksel bir modeldir. Sinir ağı, paralel ve dağıtılmış veri hesaplama, uyarlanabilir özellik öğrenme, iyi hata toleransı ve sağlamlık becerisine sahiptir (Wang vd., 2020).

YSA, biyolojik sinir sistemine benzeyen bir tekniktir. Edinilen bilgiyi saklayabilir ve çıktı değerlerini tahmin etmek için kullanılabilir hale getirebilir. Öğrenme süreciyle verilen girdi değerlerine uyum sağlamak YSA'yı oldukça hassas bir makine öğrenmesi tekniği yapmaktadır. Böylece YSA, son yıllarda en öne çıkan makine öğrenmesi tekniği haline gelmiştir (Paturi ve Cheruku, 2020).

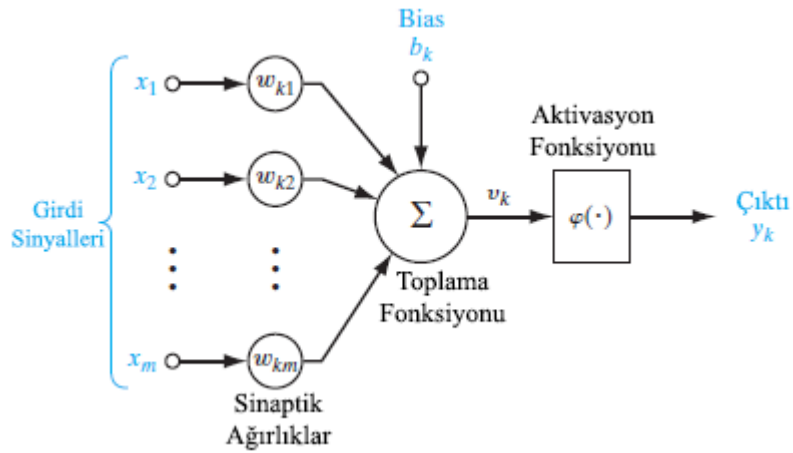
YSA, birbirine bağlı çok sayıda bilgi işleme birimi tarafından oluşturulur. Bu bilgi işleme birimlerine yapay nöronlar denir. YSA, gerçek biyolojik sinir sistemlerinin yapısı ve işleyişinden esinlenmiştir. Bu sistemin ana birimi, nöron adı verilen özel bir hücre türüdür. Bir nöron, bir hücre gövdesi (soma), dendritler ve tek bir aksondan oluşur. Hem akson hem de dendritler, hücre gövdesinden çıkan ince liflerin şekline sahiptir. Nöronların temel işlevi, sinyalleri (bilgileri) diğer hücrelere iletmek ve dönüştürmektir. Sinyaller, dendritler yoluyla bir nörona verilir ve aksonun aşağısındaki diğer nöronlara



gönderilir. Aksonlar, diğer nöronların dendritleri ile biyokimyasal bağlantılar - sinapslar yoluyla bağlanır. Sinapslar aracılığıyla birbirine bağlanan nöronlar bir sinir ağı oluşturur (Rabiej ve Rabiej, 2021). Yapay nöron, biyolojik nöronu simüle ederek yapay nöronun yapısını oluşturur. Yapay nöron çoklu bağlantı ağırlıkları, bir toplama terimi ve doğrusal olmayan aktivasyon fonksiyonu olmak üzere üç bölümden oluşmaktadır (Wang vd., 2020). Şekil 3.3'te bir biyolojik sinir ağının temsili gösterimi, Şekil 3.4'te ise yapay bir nöronun temsili gösterimi yer almaktadır.



Şekil 3.3. Bir biyolojik nöronun temsili gösterimi (Saxena vd., 2020)



Şekil 3.4. Bir yapay nöronun temsili gösterimi (Haykin, 2009)

Genel olarak, bir nöronun çıktı sinyali Denklem 3.1'deki gibi hesaplanmaktadır.

$$y_k = \varphi \left( \sum_{j=1}^m w_{kj} x_j + b_k \right) \quad (3.1)$$

Denklemden  $x_1, x_2, \dots, x_m$  girdi sinyallerini,  $w_{k1}, w_{k2}, \dots, w_{kj}$  k nöronunun ilgili sinaptik ağırlıklarını,  $b_k$  biası,  $\varphi(\cdot)$  aktivasyon fonksiyonunu ve  $y_k$  nöronun çıktı sinyalini ifade etmektedir.

Yapay sinir hücresinin bileşenleri aşağıdaki gibidir:

- Girdiler: Girdiler, yapay sinir hücresine dışarıdan alınan verilerdir. Bu veriler, ağırlık öğrenmesi istenen örnekler tarafından sağlandığı gibi başka bir sinir hücresinden veya yapay sinir hücresinin kendisinden de gelebilir (Arıkan Kargı, 2015).
- Ağırlıklar: YSA'daki hücrelere gelen girdiler geldikleri bağlantıların ağırlığıyla çarpıldıktan sonra ulaşmaktadır. Bu yöntemle girdilerin çıktı verileri üzerindeki tesiri ayarlanabilmektedir. Girdilerle çarpılan ağırlık değerleri pozitif veya negatif olabileceği gibi sıfır da olabilir. Ağırlığın sıfır olması durumunda girdilerin çıktılar üzerinde hiçbir tesiri bulunmamaktadır (Ertaylan vd., 2021).
- Toplama fonksiyonu: Bu katman, nöronların soması gibi işlev görmekte olup alınan giriş sinyalini toplamaktadır (Singh ve Manure, 2020). Toplama fonksiyonlarından en yaygın olarak kullanılan ağırlıklı toplamı verenidir. Dentrit-hücreye gelen her bir girdiyi, işlem elemanına bağlayan ağırlık değeriyle çarpılarak net girdiyi hesaplayan fonksiyona ağırlıklı ortalama toplama fonksiyonu denir (Metin vd., 2020).
- Aktivasyon fonksiyonu: Toplama fonksiyonu neticesinde elde edilen değer bir fonksiyondan geçirilerek çıktıya yönlendirildiği yerdir (Rençber, 2018). Aktivasyon fonksiyonları, bir düğümün girdisini, sonraki katmana girdi olarak kullanılan bir çıktı sinyaline dönüştürür. Aktivasyon fonksiyonu, YSA'nın özelliklerini tanımlar ve herhangi bir matematiksel fonksiyon olabilir. Aktivasyon fonksiyonu, YSA'nın çözmesi gereken probleme dayanarak seçilmektedir (Demuth ve Beale, 2004). Aktivasyon fonksiyonu olarak birçok fonksiyon kullanılabilir. Bunlar aşağıda sıralanmıştır:

- Keskin-limitli aktivasyon fonksiyonu
- Simetrik keskin-limitli aktivasyon fonksiyonu
- Tanjant sigmoid aktivasyon fonksiyonu
- Lojistik sigmoid aktivasyon fonksiyonu
- Doygunluk doğrusal aktivasyon fonksiyonu
- Simetrik doygunluk doğrusal aktivasyon fonksiyonu
- Doğrusal aktivasyon fonksiyonu
- Pozitif doğrusal aktivasyon fonksiyonu
- Üçgensel tabanlı fonksiyon
- Radyal tabanlı fonksiyon
- Esnek / türevlenebilir (softmax) aktivasyon fonksiyonu
- Rekabetçi aktivasyon fonksiyonu
- Ölçme ve sınıflandırma (bias): Toplama fonksiyonunun çıktısı bazen sifıra eşit olmaktadır. Bu tür bir durumdan kaçınmak için modele bir bias (önyargı) faktörü eklenir (Meesaraganda vd., 2019). Bias, çıktının değerini değiştirmek için nörona eklenen ekstra bir skalerdir ve bir sinir ağının verilere daha iyi uymasına yardımcı olabilmektedir (Zhang vd., 2020).
- Çıktılar: Hücreye ait aktivasyon fonksiyonu sonucu nöronun çıktı sonucu olmaktadır. Çıktı değeri gerekirse YSA'nın sonuç değeri olarak kullanılır ya da diğer katmanlara girdi olarak iletilerek tekrar ağın içinde kullanılır (Ertaylan vd., 2021).

YSA, mühendislik ve bilimle ilgili çeşitli problemlerde kullanılabilir. YSA'nın olası uygulama alanları aşağıdaki şekilde kategorilendirilebilir (da Silva vd., 2018):

- Evrensel eğri uydurma (fonksiyon yaklaşımı): Amaç, belirli bir sistemin değişkenleri arasındaki fonksiyonel ilişkiyi bilinen bir anlamlı değerler kümesinden haritalamaktır. Bu uygulamalar olabildiğince çeşitlidir ve genellikle geleneksel yöntemler kullanılarak modellenmesi zor olan haritalama süreçlerini içerir.
- Süreç kontrolü: Bu uygulama kategorisi, kalite, verimlilik ve güvenlik gereksinimlerini karşılayabilen kontrol eylemlerinin tanımlanmasından oluşur.

Mevcut birden fazla uygulama arasında, sinir denetleyicileri robotik, uçaklar, asansörler, cihazlar, uydular ve benzerleri için özellikle ilgi çekicidir.

- Örüntü tanıma/sınıflandırma: Amaç, görüntü, konuşma ve yazma tanıma durumunda olduđu gibi, belirli bir girdi modelini önceden tanımlanmış sınıflardan biriyle ilişkilendirmektir. Bu durumda, ele alınmakta olan problem, ayrı ve bilinen bir çıktı kümesine sahiptir.
- Veri kümeleme: Amaç, gruplanmalarına (kümelenmelerine) izin vermek için çeşitli girdi modellerinin benzerliklerini ve özelliklerini tespit etmek ve tanımlamaktır. Veri kümeleme; otomatik sınıf tanımlama ve veri madenciliđi gibi uygulamalar içermektedir.
- Tahmin sistemi: Bu sistem kategorisinin amacı, belirli bir sürecin gelecekteki değerlerini, kendi alanında gözlemlenen önceki birkaç örneđi dikkate alarak tahmin etmektir. Bilinen uygulamalar arasında, zaman serisi tahmini, borsa tahmini, hava durumu tahmini vb. sistemler bulmak mümkündür.
- Sistem optimizasyonu: Amaç, bir problemi dođru bir şekilde haritalamak için nihai kısıtlamalara uyarak bir amaç fonksiyonunu en aza indirmek veya maksimize etmektir. YSA'dan yararlanabilecek optimizasyon problemleri arasında en önemlisi kısıtlı optimizasyon problemleri, dinamik programlama ve kombinasyonel optimizasyon yer almaktadır.
- İlişkisel bellek: Amaç, iç unsurları belirsiz veya yanlış olsa bile dođru bir model elde etmektir. Görüntü işleme, sinyal iletimi, yazılı karakter tanımlama örnek olarak gösterilebilir.

YSA'nın avantajları aşığıdaki gibi sıralanabilir (Chattopadhyay, 2011; Kurt, 2017; Silaparasetty, 2020):


- Aynı sinir ađı algoritması birçok farklı sistem için çalışabildiğinden sinir ađları çok az insan deneyimi gerektirmektedir.
- Sinir ađları, işin çođunu bilgisayarlara taşıyarak insan gücünden tasarruf edilmesine olanak sağlamaktadır.
- Sinir ađının bir öđesi başarısız olsa bile çalışmaya devam eder. Bu, paralel dođasından kaynaklanmaktadır.

- Tahmin ediciler ve tahminler arasındaki karmaşık doğrusal olmayan ilişkileri belirleme yeteneğine sahiptir.
- YSA, gürültülü verilerle çalışma yeteneğine sahiptir ve bağımsız değişkenler arasındaki etkileşimleri tespit edebilir.
- Uyarlanabilir ve akıllı bir sistem olduğundan, programlanmalarına gerek yoktur. Bu da birçok uygulamada YSA'nın uygulanmasını oldukça kolaylaştırmaktadır.
- Bir sinir ağı, geleneksel bir ağdan daha fazla hata toleransı sağlayabilir.

YSA'nın dezavantajları ise aşağıdaki gibi sıralanabilir (Abdallah vd., 2020; Kurt, 2017; Silaparasetty, 2020):

- Yüksek doğruluk gerektiren mantıksal ve aritmetik problemleri ele almakta zayıftırlar.
- YSA'nın başarılı bir şekilde eğitilmesi için büyük veri setlerine ihtiyaç duyulmaktadır.
- Büyük veri setleri için çok fazla eğitim süresi gerektirirler.
- Yetersiz veya yanlış tahminlere yol açabilecek aşırı öğrenmeye eğilimlidirler.
- Nöron sayısının artması, ağı karmaşıklığını artırır.
- Katman sayısını ve katman başına nöron sayısını belirlemek için biraz deneme yanılma işlemi yapılır. Bu zaman alıcıdır.

YSA modellerinin tasarımı, her model geliştirme adımını uygulamak için kesin bir yöntem bulunmaması nedeniyle, genellikle bir bilimden çok bir sanat olarak görülebilir. Model geliştirme süreci sekiz ana adımdan oluşmaktadır. Bunlar sırasıyla veri toplama, veri ön işleme, girdi değişkenlerinin (veya tahmin edicilerin) seçimi, veri bölme, model mimarisi seçimi, model yapısının belirlenmesi, model eğitimi ve model doğrulamadır (Cabaneros vd., 2019). Şekil 3.5, veri süreci, yapı belirleme ve kesinlik doğrulaması da dahil olmak üzere bir YSA modeli oluşturmak için akış şemasını göstermektedir.



**Şekil 3.5.** YSA modeli oluşturma akış şeması (Jiang vd., 2020a)

YSA'nın nasıl oluşturulacağı konusunda kesin bir kabul bulunmamakla birlikte, deneysel yöntemlerle veya literatürdeki çalışma ve varsayımlara atıfta bulunularak bir probleme ve veri setine uygun bir model oluşturulabilir. Yapılandırma türü, eğitim algoritması, çeşitli fonksiyonlar, ağırlıklar ve dengeler YSA modelinin doğruluğunu etkiler (Mitrofanov vd., 2020).

YSA'nın yetersiz veya bilgilendirici olmayan girdi değişkenlerine sahip olması modelin optimallikten uzaklaşmasına sebep olabilir. Optimal girdi değişkenleri kümesini neyin oluşturduğunu tanımlamak, öncelikle girdi değişkenlerinin seçiminin model performansı

üzerindeki etkisinin dikkate alınmasını gerektirmektedir. Aşağıdaki parametreler, dikkate alınması gereken önemli hususları özetlemektedir (May vd., 2011):

- Alaka düzeyi: Muhtemelen en bariz endişe, çok az değişkenin seçilmesi veya seçilen girdi değişkenleri kümesinin yeterince bilgilendirici olmamasıdır. Bu durumda, çıktının bazı davranışları seçilen girdi değişkenleri tarafından açıklanamadığından, sonuç düşük performans gösteren bir modeldir. Çoğu durumda, bir modelleyicinin söz konusu sistem hakkında bazı uzmanlık bilgisine sahip olacağını varsaymak mantıklıdır. Bu sayede mevcut verileri araştırmış ve makul bir aday girdi değişkenleri kümesine ulaşmış olacaktır. Model geliştirmenin önsel varsayımı, mevcut aday değişkenlerden en az birinin veya daha fazlasının çıktı davranışının tamamını olmasa da bazılarını tanımlayabildiğidir. Mevcut adaylardan hiçbirinin iyi tahmin edici olmaması durumunda, model geliştirme problemi çözülemez. Bundan dolayı model geliştirme görevini yeniden gözden geçirmeden önce mevcut verileri ve model çıktısının seçimini yeniden gözden geçirmek ve daha fazla ölçüm veya gözlem yapmak gerekli olabilir.
- Hesaplama güçlüğü: Modele fazla sayıda girdi değişkeni dahil etmenin en belirgin etkisi, bir YSA'nın boyutunun artmasıdır. Bu da ağın sorgulanmasıyla ilişkili hesaplama yükünü artırır. Ayrıca, ek değişkenler YSA geliştirme sırasında üstlenilebilecek herhangi bir veri ön işleme adımına daha fazla yük bindirir.
- Eğitim zorluğu: Bir YSA'yı eğitime görevi, gereksiz ve ilgisiz girdi değişkenlerinin dahil edilmesi nedeniyle daha zor hale gelebilmektedir. Fazlalık değişkenlerin etkisi, yerel olarak optimal hata değerleri verebilen daha fazla parametre kombinasyonu olduğundan, modelin parametre alanı üzerinden yansıtılan hata fonksiyonundaki yerel optimizasyon sayısını artırmaktır. Gradyan azaltmaya dayanan geri yayılma algoritması gibi algoritmaların bu nedenle yerel bir optimuma yakınsama olasılığı daha yüksektir ve bu da zayıf genelleme performansına neden olur. Ağın eğitimi de daha yavaştır çünkü artık parametreler ve hata arasındaki ilişkiyi eşleştirmek daha zordur. Alakasız değişkenler modele gürültü ekler ve bu da öğrenme sürecini engeller. Eğitim algoritması, çıktı değişkeni ile ilgisi olmayan ağırlıkları ayarlamak için kaynakları harcayabilir veya gürültü, önemli girdi-çıkı ilişkilerini maskeleyebilir. Sonuç olarak, model

geliştirmenin hesaplama yüküne ek olarak, neredeyse global bir optimum hatayı belirlemek için eğitim algoritmasının daha birçok yinleme yapması gerekebilir.

- Boyutsallık: Bir modelin boyutsallığı doğrusal olarak arttıkça, modelleme problemi alanının toplam hacmi de katlanarak artmaktadır. Bu nedenle, belirli bir fonksiyonu model parametre alanı üzerinde yeterli güvenlikle haritalamak için, katlanarak artan sayıda örnek gereklidir. Alternatif olarak, genellikle gerçek dünya uygulamalarında olduğu gibi sınırlı sayıda verinin mevcut olduğu durumlarda, gerçek haritalamanın bulunduğu dair güven veya kesinliğin azalacağı söylenebilir.
- Anlaşılabilirlik: Birçok uygulamada, YSA kara kutu modeli olarak ifade edilmektedir. Ancak, YSA modelleyicileri, veri ve veri madenciliğinden bilgi keşfi için YSA modellerinin geliştirilmesiyle YSA ile giderek daha fazla ilgilenmektedir. Verilerden bilgi keşfinin amacı, bir sürecin gözlemlerine dayalı bir YSA'yı eğitmek ve daha sonra öğrendiği süreç davranışını daha iyi anlamak için YSA'yı sorgulamaktır. Ağın fazlalığını ve boyutunu minimize ederek YSA'nın karmaşıklığını azaltmak, veri madenciliği algoritmalarının performansını önemli ölçüde artırmaktadır.

Bir YSA'daki gizli katman sayısı olması gerekenden fazla ise, bu YSA'nın ezberlemesine ve yeni verilere karşı başarılı tahmin gerçekleştirme olasılığının azalmasına neden olabilir. Yetersiz sayıda gizli katman, sorunu çözmek için yetersiz YSA'ya neden olabilir. YSA'nın kurulması sırasında karşılaşılan bir diğer sorun ise katmanlardaki nöron sayılarının belirlenmesidir. Giriş katmanında giriş sayısı kadar nöron, çıkış katmanında ise istenilen çıktı kadar nöron bulunur. Ancak YSA'nın doğası gereği gizli katmanlarda ne olduğu bilinmemektedir ve bu nedenle gizli katmanlardaki nöronlar hesaplanamaz. Bu nedenle en ideal nöron sayısını hesaplamak için uygun bir yöntem yoktur, ancak deneysel yöntemlerle belirlenebilir (Güven ve Şimşir, 2020). Nöronların sayısı hakkında bir başlangıç noktasına sahip olmak için (gizli katman  $h$  için  $N_h$ ), bazı deneysel yöntemler aşağıdaki gibidir (Rosa vd., 2019):

- Huang (2003) makalesinde, iki gizli katman ağı için  $N_{h=1} = \sqrt{(m+2)N} + 2\sqrt{\frac{N}{m+2}}$  ve  $N_{h=2} = m\sqrt{\frac{N}{m+2}}$  formüllerinin küçük bir hatayla  $N$  adet örneği (girdi-



çıkıttı çiftlerini) öngörebilen bir ađ sađladıđını bildirmiřtir. Formülde N, düşük hata ile öđrenilecek örnek sayısını, m ise çıkıttı deđiřkenlerinin sayısını temsil etmektedir.

- Ke ve Liu (2008) yapmıř oldukları alıřmada önerdikleri  $N_{h=L} = \frac{N_{in} + \sqrt{N_p}}{L}$  formülünü 40 farklı test durumu için test etmiřlerdir. Yazarlar elde ettikleri sonuçlardan hareketle önerdikleri formülün gizli katmanlardaki optimum nöron sayısını hesaplanması için kullanılabileceđini belirtmiřlerdir. Formülde  $N_{in}$ , girdi nöronlarının sayısını;  $N_p$ , girdi örneklerinin sayısını, L ise gizli katman sayısını ifade etmektedir.
- Trenn (2008), YSA'nın modellemeye alıřtıđı fonksiyonla ilgili olarak, fonksiyonun belirli bir yaklařım sırasına ulařmasını sađlamak için gerekli sayıda gizli nöronu hesaplamak için bir teorem önermiřtir. N yaklařım sırası, bařlangıtaki N derecesinin türevinin YSA tarafından tanımlanan fonksiyon için aynı olduđunu belirtir. Teoreme iliřkin formüller ařađıdaki gibidir. Formüllerde  $n_0$  modelin girdi sayısını, N ise gizli katmanlardaki nöron sayısını ifade etmektedir.

$$\left\{ \begin{array}{l} \sum_{h=1}^L N_h \geq \frac{(N + n_0)}{n_0 + 2}, \quad \left( \frac{N + n_0}{n_0} \right) \leq n_0^2 + 3n_0 + 2\sqrt{n_0^3} + 4\sqrt{n_0} \text{ ise} \\ \sum_{h=1}^L N_h \geq 2 \sqrt{\left( \frac{N + n_0}{n_0} \right) + 2n_0 + 2 - n_0 - 3}, \quad \text{aksi halde} \end{array} \right.$$

- Toplam gizli nöron sayısını seçmek için kullanılabilecek bazı temel kurallar vardır. Bunlar:
  - Gizli nöronların sayısı, girdi katmanının büyüklüđü ile çıkıttı katmanının büyüklüđü arasında olmalıdır.
  - Gizli nöronların sayısı, çıkıttı katmanının büyüklüđü ile girdi katmanının büyüklüđünün üçte ikisinin toplamına eřittir.
  - Gizli nöronların sayısı, girdi katmanının iki katından az olmalıdır.
- En basit kurallardan biri deneme yanılmadır. Gizli katmanlar için farklı birim sayısı kombinasyonlarına sahip eđitim ađları ile alıřır ve daha iyi sonuç getireni


kaydeder. Bu yöntemle en büyük problemi, bir YSA'nın eğitimi genellikle uzun sürdüğü için zaman alıcı olmasıdır. Başlangıçta, gizli nöronların sayısı deneysel yöntemlerden biri kullanılarak ayarlanabilir, ancak sonunda, bu parametrelerin ince ayarı, daha iyi sonuçlara imkân veren modelin araştırılması için bu yöntem kullanılarak gerçekleştirilmelidir.

Bir sinir ağının gizli katmanlarının optimum konfigürasyonunun belirlenmesini birçok faktör etkileyebilir. Bu faktörler arasında eğitim çifti sayısı, giriş ve çıkış katmanlarındaki düğüm sayısı ve giriş ve çıkış verileri arasındaki ilişkiler bulunur. Beyin ne kadar büyükse modelin o kadar iyi olacağı fikrine dayanan birçok gizli katman ve çok sayıda düğüm içeren bir ağ tasarlamak kulağa cazip gelebilir. Ancak ele alınan model için çok büyük bir gizli katman yapısı karmaşık olduğundan, ağ, aralarındaki ilişkileri öğrenmek yerine girdi ve çıktıları ezberleme eğilimine girebilir. Bu tutum da zayıf bir performans modeliyle sonuçlanabilir (Delgado vd., 2020).

Model doğruluğunu tahmin etmek ve tipik ezberleme problemiyle başa çıkmak için, sinir ağı modeli için orijinal veri seti rastgele olarak eğitim, doğrulama ve test verileri olmak üzere üç veri setine bölünmektedir. Eğitim veri seti, ağı eğitmek için kullanılmaktadır. Doğrulama verileri ise genellikle eğitim süreci sırasında ağı değerlendirmek için girdi verilerinden seçilmektedir. Bu veriler, bir ağın yeni bir veri kümesi için genelleştirilmesine yardımcı olmak için kullanılmaktadır. Test verileri de eğitilmiş ağın performansını test etmek için kullanılan bağımsız bir veri setidir. Her veri setinin bölünme oranı, veri setinin boyutuna veya veri setinin yapısına bağlı olarak değişebilmektedir. Ancak yaygın olarak kullanılan bölünme oranları eğitim, doğrulama ve test için sırasıyla “%80 / %10 / %10”, “%70 / %15 / %15” ve “%60 / %20 / %20”dir (Kim vd., 2020a; Soltangharai vd., 2020).

Beklendiği gibi, ağırlıklar eğitim aşamasında yinelemeli bir prosedürle ayarlanır. Bu prosedür yoğun hesaplama çabası gerektirir ve eğitim setleri adı verilen belirli sayıda girdi-hedef çifti kullanır. Eğitimde, belirli bir hata fonksiyonunu en aza indiren ağırlıkların değerleri aranır (Ciaburro vd., 2020).

Sinir ağıları, paralel olarak çalışan basit işletim ögeleridir. Doğada, sinir ağlarının performansı, bileşenlerin nasıl bağlandığına göre belirlenir. YSA, her bir bağlantının miktarı ağırlık olarak ayarlanarak bileşenler arasındaki bağlantıların ayarlandığı doğal bir sinir ağının yapay bir modelidir. YSA'nın unsurları arasındaki her bağlantının ağırlığını ayarlamaya eğitim denir. Şekil 3.6'da ağ, girdiyi ilgili çıktıyla eşleştirmeye göre ayarlanmıştır. Genel olarak, ağırlıkları uygun şekilde ayarlamak için çok sayıda girdi ve çıktı çifti gerekir.



**Şekil 3.6.** Sinir ağının çalışma prensibi (Kashani vd., 2020)

Eğitim sürecinde, hedef değerler ile gerçek veriler arasında karşılaştırma yapılır. Tahmin edilen çıktılar ile hedef çıktılar arasındaki fark, YSA hatasını tanımlamak için belirlenir. Her eğitim kaydı için üretilen hata, amaç fonksiyonunun hesaplanmasında kullanılır. Daha sonra, eğitim öğrenme algoritması, toplam YSA hatalarını tüm düğümleri bağlayan ağırlığa yeniden tahsis etmek için kullanılır. Ağırlık ayarlama süreci, öğrenme ve bozulma oranları ile kontrol edilir. Öğrenme oranı, eğitim sürecindeki aşırı ağırlık değişikliklerini kontrol etmek için kullanılırken, bozulma oranı ağırlık değerindeki en düşük değişikliği kontrol etmek için kullanılır. Optimizasyon algoritması, YSA ağırlıkları hata toleransına ulaşıncaya kadar birkaç eğitim kaydının hatasını en aza indirmek için sinir ağı yapısında da kullanılır. Gizli katmandaki bir bias düğümü, ağırlıklı toplamı değerine yükseltmek için kullanılır (Azim, 2020).

YSA'yı eğitmek için kullanılan Gradyan veya Jacobian tabanlı eğitim algoritmaları aşağıdaki gibidir:

- Levenberg-Marquardt geri yayılım algoritması (trainlm)
- Bayes düzenlenmesi geri yayılım algoritması (Bayesian regularization backpropagation) (trainbr)
- Gradyan Tabanlı Öğrenme Algoritmaları

- Gradyan inişi geri yayılım algoritması (Gradient descent backpropagation) (traingd)
- Adaptif (uyarlamalı) gradyan inişi geri yayılım algoritması (Gradient descent with adaptive learning rate backpropagation) (traingda)
- Momentumlu gradyan inişi geri yayılım algoritması (Gradient descent with momentum backpropagation) (traingdm)
- Momentumlu ve adaptif (uyarlamalı) öğrenme oranlı gradyan inişi geri yayılım algoritması (Gradient descent with momentum and adaptive learning rate backpropagation) (traingdx)
- Esnek geri yayılım algoritması (Resilient backpropagation) (trainrp)
- Konjuge Gradyan Algoritmaları
  - Fletcher-Reeves güncellemeli konjüge gradyan geri yayılım algoritması (Conjugate gradient backpropagation with Fletcher-Reeves updates) (traingcf)
  - Polak-Ribière güncellemeli konjüge gradyan geri yayılım algoritması (Conjugate gradient backpropagation with Polak-Ribière updates) (traingcp)
  - Powell-Beale yeniden başlamalı konjüge gradyan geri yayılım algoritması (Conjugate gradient backpropagation with Powell-Beale restarts) (traingcb)
  - Ölçeklenmiş konjüge gradyan geri yayılım algoritması (Scaled conjugate gradient backpropagation) (traingscg)
- Quasi-Newton Teknikleri
  - BFGS Quasi-Newton geri yayılım algoritması (BFGS Quasi-Newton backpropagation) (trainbfg)
  - Tek adım sekant geri yayılım algoritması (One-step secant backpropagation) (trainoss)

Çalışmada YSA'yı eğitmek için Levenberg-Marquardt (LM), Bayes Düzenlenmesi (BR) ve Ölçeklenmiş Konjüge Gradyan (SCG) eğitim algoritmalarından faydalanılmıştır.

LM algoritması, YSA aracılığıyla zaman serisi tahmini yapmak için yaygın olarak kullanılan bir eğitim algoritmasıdır. LM algoritması, eğitim için öğrenme süresini kısaltmakta ve yakınsama sürecini hızlandırmaktadır (Jung vd., 2020). LM algoritması özellikle doğrusal olmayan en küçük kareler problemlerini çözmek için kullanılmaktadır (Negash ve Yaw, 2020). Bu algoritma, Gradyan İniş ve Gauss-Newton yöntemlerinin bir kombinasyonudur ve bunlar arasında enterpolasyonlar yapar. Elde edilen çözüm minimumdan uzak olduğunda algoritma Gradyan İniş yöntemi gibi, çözüm minimuma yakınsa Gauss-Newton yöntemi gibi davranır. Bu teknik, Hessian matrisini hesaplamadan ikinci mertebe eğitim hızına ulaşmak için oluşturulmuştur. Bunun yerine gradyan matrisi ve Jacobian matrisi ile çalışır. LM algoritmasının ana formu Denklem 3.2'deki gibi gösterilebilir (Ebrahimzadeh vd., 2022):

$$w_{k+1} = w_k - [J^T J + \mu I]^{-1} J^T e \quad (3.2)$$

Denklemden J Jacobian matrisini,  $J^T J$  Hessian matrisini,  $w_k$  k. iterasyonda ağırlıkların  $\mu$  öğrenme aşamasını vurgulayan skaler bir değeri (Marquardt değeri), I birim matrisini, e ağ hatası vektörünü,  $J^T e$  Gradyan matrisini ifade etmektedir.  $\mu$  çok küçük olduğunda, LM algoritması daha çok Gauss-Newton yöntemi gibi davranır ve  $\mu$  çok büyük olduğunda, LM Gradyan İniş yöntemine yaklaşır.

LM algoritması yaygın olarak kullanılan bir yöntem olmasına rağmen, bu algoritma yalnızca yerel bir minimum elde etmekle sınırlıdır. Bu da LM algoritmasının genelleme için uygun olmadığı anlamına gelmektedir. BR Algoritması, karesi alınan ağırlıkların ve karesi alınan hataların doğrusal bir kombinasyonunu içeren bir fonksiyonun minimizasyonunu hedeflemektedir. BR algoritması, bu lineer kombinasyonu, ağ eğitimi sona erdiğinde elde edilen ağırlıkların genelleştirme niteliklerini iyileştirecek şekilde değiştirir. BR, LM algoritmasına ve ayrıca değişkenlere (ağırlıklar ve bias) göre amaç fonksiyonunun Jacobian  $J$ 'sini hesaplamak için kullanılan hataların geriye doğru yayılmasına dayanır. Her değişken LM algoritmasına göre ayarlanır ve amaç fonksiyonunun indirgenmiş bir değeri elde edilene kadar artırılan uyarlanabilir bir değer kullanılır. O anda, değişiklikler ağırlıklara uygulanır ve uyarlanabilir değer düşürülür (Lungu vd., 2016).

BR kullanılarak eğitilen sinir ağları, LM algoritmasına kıyasla daha fazla genellemeye sahiptir ve daha güçlü sonuçlar vermektedir (Rahimi vd., 2018). BR algoritmasının işlenmesi genellikle daha fazla zaman almakta ancak gürültülü veri kümeleri için iyi bir genellemeyle sonuçlanmaktadır. Ayrıca standart geri yayılım ağlarından daha güçlüdür ve uzun çapraz doğrulama prosedürlerine olan ihtiyacı azaltmakta veya ortadan kaldırmaktadır (Roghanchi ve Kocsis, 2019). Genel olarak, LM algoritması daha hızlıdır. BR algoritması ise karmaşık problemlerde daha iyi çalışır.

BR algoritması, doğru kombinasyonu belirlemek için karesel hata gruplarını azaltır ve uygun ağırlıkları bulur. Bu sayede kolayca genelleştirilebilen bir ağ oluşturabilmektedir. BR algoritması, ağ ağırlıklarını  $F(w)$  olarak gösterilen eğitim amaç fonksiyonuna verir. Eğitim amaç fonksiyonu Denklem 3.3'te gösterilmiştir (Rawat vd., 2018).

$$F(w) = \alpha E_w + \beta E_D \quad (3.3)$$

Denklemden  $E_w$  ağ ağırlıklarının karelerinin toplamını,  $E_D$  ağ hatalarının toplamını ve  $\alpha$  ile  $\beta$  amaç fonksiyonu parametrelerini ifade etmektedir. Ağırlık vektörünü ayarlamak ve eğitim setini seçmek için Gauss tipi dağılım dikkate alındığından bu parametreler bazı cebirsel işlemlerle optimize edilebilir. Daha sonra, LM süreciyle  $F(w)$  minimize edilir ve böylece ağırlıklar güncellenir. Bu süreç, tatmin edici bir yakınsama koşulu sağlanana kadar yinelenmektedir (Mahdaviara vd., 2022).

BR algoritmasının ana avantajlarından biri, doğrulama prosedüründen kaçınmasıdır. Bazı problemlerde, doğrulamayı sağlamak için verilerin bir kısmını ayırmak mümkün olmadığından BR algoritması sayesinde bu durumdan kaçınılır. Bu algoritmanın bir başka avantajı, çeşitli sayıda gizli nöronun test edilmesi ihtiyacını azaltabilmesi veya hatta ortadan kaldırabilmesidir. Üçüncü bir değişken olan  $\gamma$  uygulanarak, ağ tarafından kullanılan ağırlıkların etkisi kontrol edilebilir ve böylece ağırlıkların karmaşıklığı hakkında bilgi elde etmek mümkündür (Lungu vd., 2016).

Hızlı yakınsama ve doğruluk arasındaki orta yol genellikle üçüncü bir eğitim algoritması olan SCG algoritması ile temsil edilir. SCG algoritması, büyük doğrusal denklem

sistemlerinin problemini çözmek için kullanılan bir yineleme algoritmasıdır (Di Nunno ve Granata, 2020). SCG algoritması kritik hale gelebilecek kullanıcıya bağlı parametrelerin kullanımını önler ve ayrıca adım boyutunu (ağırlık güncellemesinin uzunluğu) belirlerken LM ve BR algoritmaları tarafından kullanılan bazı zaman alıcı prosedürlerden kaçınma avantajına sahiptir. Bu aşamada, diğer algoritmalar, her yineleme için bir satır araması gerektirir ve bu faaliyet her arama için ağırlık güncellemesinin birkaç kez hesaplanması gerektiğinden kaynak tüketen bir işlemdir. SCG algoritması, konjüge gradyan yaklaşımını ve LM yaklaşımını birleştirerek bu satır aramasını önler (Lungu vd., 2016). SCG yöntemi Denklem 3.4'teki gibi hesaplanabilir (Kim vd., 2020b).

$$S_k = \frac{E'(w_k + \sigma_k p_k) - E'(w_k)}{\sigma_k} + \lambda_k p_k \quad (3.4)$$

Denklemden  $S_k$  ölçeklendirme faktörünü,  $E'$  global hata fonksiyonunun gradyanını,  $\lambda_k$  başlangıç değerini ( $0 < \lambda_1 \leq 10^{-6}$ ),  $p_k$  konjüge ağırlık vektörünü,  $w_k$  ağırlık vektörünü ve  $\sigma_k$  başlangıç değerini ( $0 < \sigma_1 \leq 10^{-4}$ ) ifade etmektedir.

Modeli doğrulamak için deneysel veriler ile model çıktıları arasında bir karşılaştırma yapılır. Mühendislikte, bir modelin çözümünden ve deneylerden gelen bir dizi veri sunulduğunda, modelin performansının deneysel ölçümlere göre değerlendirilmesi için nicel bir analiz yapılması önerilir (Belman-Flores vd., 2015). Ele alınacak çalışmada kurulacak YSA modellerinin etkinliğini değerlendirmek için Hata Kareler Toplamı (Sum of Squared Errors-SSE), Ortalama Karesel Hata (Mean Squared Error-MSE), Ortalama Hata Kare Kökü (Root Mean Square Error-RMSE), Ortalama Mutlak Hata (Mean Absolute Error-MAE), Ortalama Mutlak Yüzde Hatası (Mean Absolute Percentage Error-MAPE), Korelasyon Katsayısı (R) ve Belirlilik Katsayısı ( $R^2$ ) performans ölçütlerinden faydalanılmıştır. Bahsi geçen performans ölçütleri Denklem 3.5 – Denklem 3.11 arasında belirtilen formüllerle hesaplanmaktadır (da Silva ve Coury, 2020; Kalantary vd., 2020; Khaleghi vd., 2021):

$$SSE = \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (3.5)$$

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (3.6)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (3.7)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (3.8)$$

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right| * 100 \quad (3.9)$$

$$R = \frac{\sum_{i=1}^n (y_i - \bar{y}_i)(\hat{y}_i - \bar{\hat{y}}_i)}{\sqrt{\sum_{i=1}^n (y_i - \bar{y}_i)^2} \sqrt{\sum_{i=1}^n (\hat{y}_i - \bar{\hat{y}}_i)^2}} \quad (3.10)$$

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (3.11)$$

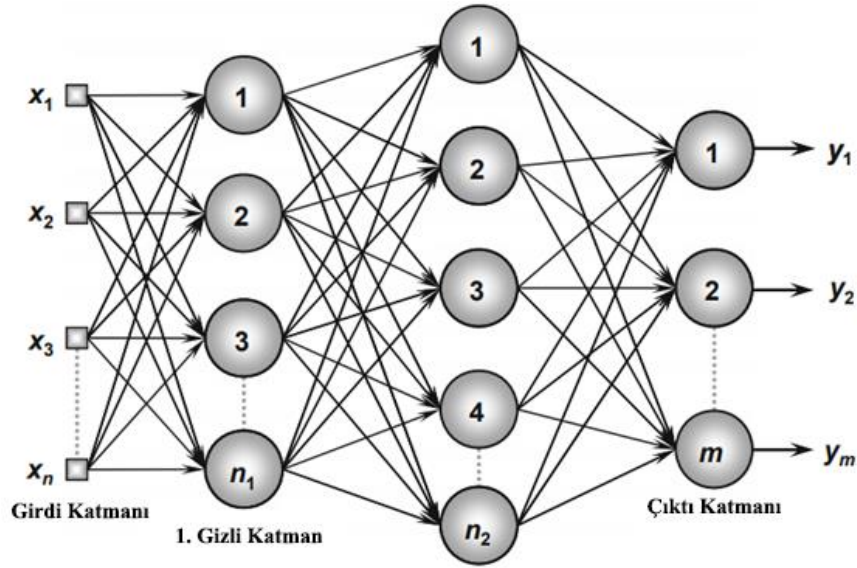
Denklemlerde  $n$  veri noktası sayısını,  $y_i$  gerçek hedefi,  $\hat{y}_i$  tahmini hedefi ve  $\bar{y}$  ortalama gözlemlenen  $y_i$ 'yi temsil etmektedir.

YSA'lar mimari yapılarına göre genellikle ileri beslemeli yapay sinir ağları ve geri beslemeli yapay sinir ağları olmak üzere iki ayrı kategoride sınıflandırılmaktadır.



### 3.2.1.1. İleri beslemeli yapay sinir ağları

Uygulamalarda oldukça yaygın kullanım alanına sahip olan ileri beslemeli çok katmanlı YSA modeli, Şekil 3.7’de görüldüğü gibi temelde giriş katmanı, gizli katman ve çıkış katmanı olmak üzere üç katmandan oluşmaktadır. İleri besleme terimi, veri özelliği çıkarma sürecinin girdi katmanından çıktı katmanına tek yönde hareket ettiğini belirtir. Girdi katmanına öğretilecek vektörler karışık bir düzeyde uygulanır. Gizli katman ise ağız zekâ içeren kısımdır. Gizli katmanda nöron sayısının belirlenmesi önem arz ettiğinden uygulamalarda az sayıda nöronla başlayarak sonra bu sayıyı artırmakla başarımlar değerlendirilmesi yapılması gerekir. Ağız çalışmasında, ağız içerisinde ileri – geri gezilerek optimum ağırlıkların elde edilmesi amaçlanır. Çıkıştaki değerlerden elde edilen hatalar ağız tekrar uygulanarak, tüm ağırlık değerleri güncellenir. Bu şekilde yapılan turlarla hata değeri seçilen hatanın altına indiğinde ağız öğrenme işlemini tamamlar. Çıkış katmanı süreç modeli için tahminler sağlayan bir veya daha fazla fonksiyondan oluşur (Jebamalar vd., 2020; Nabiyev, 2016).



Şekil 3.7. İleri beslemeli yapay sinir ağı (da Silva vd., 2017)

### 3.2.1.2. Geri beslemeli yapay sinir ağıları

Geri beslemeli yapay sinir ağıları, veri akışının yalnızca ileriye doğru olmadığı, geriye doğru da olabileceği ağ yapılarıdır. Bu yapılarda en az bir tane geri besleme çevrimi olur. Geri besleme hem aynı katmandaki hücreler arasında hem de farklı katmanlardaki nöronlar arasında olabilir. Bu yapısı sebebiyle geri beslemeli yapay sinir ağıları, doğrusal olmayan bir dinamik davranış gösterirler. Geri beslemeli yapay sinir ağılarında, bir katmandaki nöronlar kendi içinden beslenebileceği gibi, katmandaki diğer nöronlardan veya farklı katmanlardaki nöronlardan beslenebilmektedir. Bu nedenle, geri beslemeli yapay sinir ağılarında, çıktı katmanındaki bir nöron, sistemdeki girdiler ve ağırlık değerleriyle belirlenmesinin yanında, sistemdeki bazı hücrelerin bir önceki değerlerinden de etkilenebilir. Bu türdeki ağlar, çıktıdan alınan geri besleme sinyalini gizli tabaka ile girdi tabakasına gönderirler. Ağa yeni girdiler alınırken, önceden gönderilen geri besleme sinyali de göz önüne alınmış olur. Geri besleme, ağın daha doğru sonuçlar elde etmesine yardımcı olan bir unsurdur (Aydemir, 2018; Çalışkan Çavdar ve Aydın, 2018).

### 3.2.2. Doğrusal olmayan dışsal girdili otoregresif ağ (NARX)

Zaman serilerinin tahmini için dinamik sinir ağıları, zamana bağlı verileri tahmin etmek için eğitilebildikleri ve ayarlanabildikleri için en verimli algoritmalardan biridir. Dinamik sinir ağılarında hesaplanan çıktı değerleri, geri besleme döngüsü ve / veya tekrarlayan bağlantılar aracılığıyla önceki giriş ve çıkış verileri değerleri ile birlikte mevcut girdi verilerinin bir fonksiyonudur. NARX, doğrusal olmayan dinamik süreçleri modellemeye uygun, tekrarlayan dinamik bir sinir ağıdır. NARX modeli, doğrusal olmayan dinamik sistem tanımlama ve modelleme için yaygın olarak kullanılmaktadır (Jiang vd., 2020b). NARX modeli, çıktının gelecekteki değerini tahmin etmek için geçmiş girdiyi ve geçmiş çıktıyı kullanan doğrusal olmayan bir zaman serisi modelidir (Mustapa vd., 2020).

Bir NARX, geribildirim bağlantılı birkaç katmandan oluşur. Bir t zamanı için NARX modelinin çıktı değeri Denklem 3.12 ile tahmin edilebilir:


$$\hat{y}_t = f\left(y(t-1), \dots, y(t-d_y), x(t-1), \dots, x(t-d_x)\right) \quad (3.12)$$

Denklemden  $f(\cdot)$  sinir ağının haritalama fonksiyonunu,  $\hat{y}_t$  t zamanında NARX'in çıktısını (t zamanı için y'nin tahmin edilen değeri),  $y(t-1), \dots, y(t-d_y)$  NARX'in geçmiş çıktılarını,  $x(t-1), \dots, x(t-d_x)$  NARX'in girdilerini,  $d_x$  girdi gecikmelerinin sayısını ve  $d_y$  çıktı gecikmelerinin sayısını temsil etmektedir (Senturk vd., 2020). Genellikle girdi gecikmelerinin sayısı çıktı gecikmelerinin sayısına eşit olmaktadır. Uygulanan gecikmeler, ağın bellek yeteneğini temsil eder (Cerinski vd., 2020).

Zamana bağlı problemleri modellemek için düşünülebilecek YSA kategorilerinden biri, tekrarlayan sinir ağlarıdır. Tekrarlayan sinir ağlarında, bir zaman dizisi için zamansal dinamik davranış, eğitim işlemi sırasında ağ yapısı tarafından sergilenebilir ve yakalanabilir. NARX sinir ağları, dinamik olarak yönlendirilen tekrarlayan yapay sinir ağları türleridir. NARX sinir ağları, aynı yapının farklı tekrarlayan modeller için oluşturulabildiği bir veya birkaç yerel / global geri bildirim döngüsüne sahiptir (Zounemat-Kermani vd., 2019). İleri beslemeli sinir ağlarında, düğümler tek yönlü bir bilgi akışına sahip katmanlar halinde düzenlenirken, NARX sinir ağları gibi tekrarlayan ağlarda, bilgi hem ileri hem de geri yönde akar ve aynı veya önceki katmanlardaki nöronlar arasındaki bağlantılara izin verir. NARX sinir ağları modelinin ileri beslemeli sinir ağları ile karşılaştırıldığında getirdiği avantajlarından biri, modeli daha etkili kılmak için girdi parametresi sayısının azaltılmış olmasıdır (Di Nunno ve Granata, 2020).

Bir NARX ağı iki modda eğitilebilir (Desouky ve Abdelkhalik, 2019):

- Seri-Paralel (açık döngü): Bu modda tahmini çıktıyı geri beslemek yerine gerçek çıktı kullanılır. Bu nedenle, çıktının regresörü, Şekil 3.8.A'da gösterildiği gibi, yalnızca sistemin çıktısının gerçek değerleri tarafından oluşturulur.
- Paralel (kapalı döngü): Bu modda tahmini çıktılar geri beslenir ve Şekil 3.8.B'de gösterildiği gibi çıktının regresörüne dahil edilir.

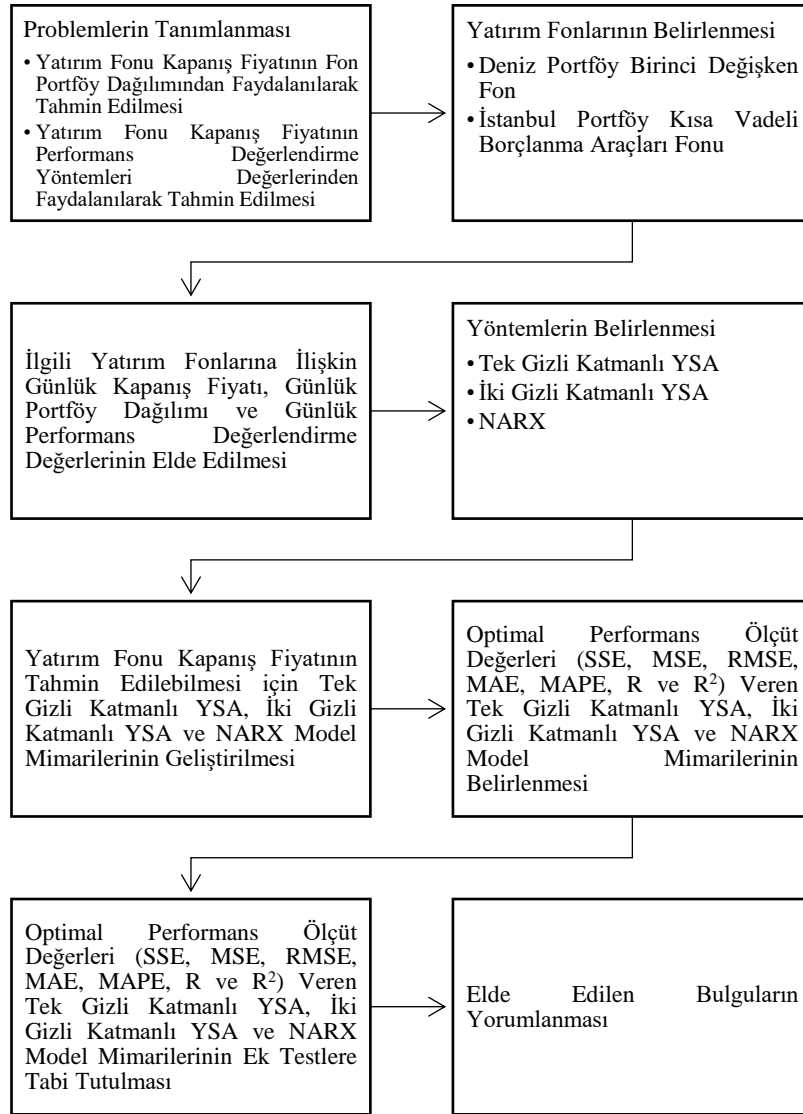


**Şekil 3.8.** NARX tasarımı **A)** Seri Paralel mimari **B)** Paralel mimari (Cui vd., 2022)

Hesaplama maliyeti açısından hem doğru hem de etkili bir sinir ağı elde etmek için ayarlanması gereken birçok parametre ve seçilmesi gereken birçok seçenek vardır. Daha spesifik olarak, bir NARX sinir ağını eğitmeden önce, otoregresif modelin iki temel parametresinin, yani girdi ( $d_x$ ) ve geri bildirim ( $d_y$ ) gecikmelerinin yanı sıra gizli katmandaki nöron sayısının belirlenmesi gerekir. En uygun mimariyi bulduktan sonraki adım, uygun eğitim yöntemini bulmaktır (Sharifzadeh vd., 2019).

#### 4. BULGULAR

Finans alan yazınında yatırım fonlarının kapanış fiyatının ve performansının birçok değişkenle öngörüldüğü çeşitli çalışmalar olmasına karşın portföy dağılımı yardımıyla ve performans değerlendirme yöntemleri değerleri yardımıyla öngörüldüğü çalışmalar uluslararası ölçekte çok sayıda değildir. Bu tez çalışmasıyla portföy dağılımı yardımıyla ve performans değerlendirme yöntemleri değerleri yardımıyla yatırım fonlarının kapanış fiyatının öngörüldüğü çalışmalara bir yenisi eklenecektir. Tez çalışmasında gerçekleştirilecek işlem adımları Şekil 4.1’de özetlenmiştir.



Şekil 4.1. Yatırım fonu kapanış fiyatının tahmin edilmesi için gerçekleştirilen işlem adımları

#### **4.1. Yatırım Fonu Kapanış Fiyatının Fon Portföy Dağılımından Faydalanılarak Tahmin Edilmesi**

Tez çalışmasında yatırım fonu kapanış fiyatının fon portföy dağılımından faydalanılarak tahmin edilmesi için tek gizli katmanlı YSA, iki gizli katmanlı YSA ve NARX model mimarileri geliştirilmiştir. Geliştirilen mimarilerde gizli katman nöron sayısı 1 ile 10 arasında sınırlandırılmıştır. Yapılan analizlerde gizli katman nöron sayısının 10 kat artması (1 ile 100 arasında sınırlandırılması) toplam analiz sayısının 12600'den 1206000'e yükselmesine yol açmaktadır. Ayrıca gizli katman nöron sayısının artması ile birim analiz süresi uzamakta ve bu durum toplam analiz süresinin analiz sayısı ile doğrusal olarak artış göstermesinin önüne geçmektedir. Bu özel duruma rağmen analiz sayısının artışıyla toplam analiz süresinin doğrusal bir artış gösterdiği varsayılırsa gizli katman nöron sayısının 10 kat artması toplam analiz süresinin 95 kat artmasına sebep olmaktadır.

##### **4.1.1. Yatırım fonu kapanış fiyatının fon portföy dağılımından faydalanılarak tahmin edilmesi için YSA model mimarilerinin geliştirilmesi**

Bir YSA probleminin çözümünde kullanılan ağ modelinin yapısı girdi sayısı, çıktı sayısı, girdi katmanı – gizli katman – çıktı katmanı arasındaki aktivasyon fonksiyonları, verinin eğitim – doğrulama – test dağılımı oranı, eğitim tur (epoch) sayısı ve hata hedefi gibi parametreleri içermektedir. Önerilen ağ modelinin tasarımında kullanılan parametreler, analizde faydalanılan eğitim algoritmalarına göre Çizelge 4.1'de gösterildiği gibi sınıflandırılmıştır.

**Çizelge 4.1.** YSA algoritmasının tasarım parametreleri

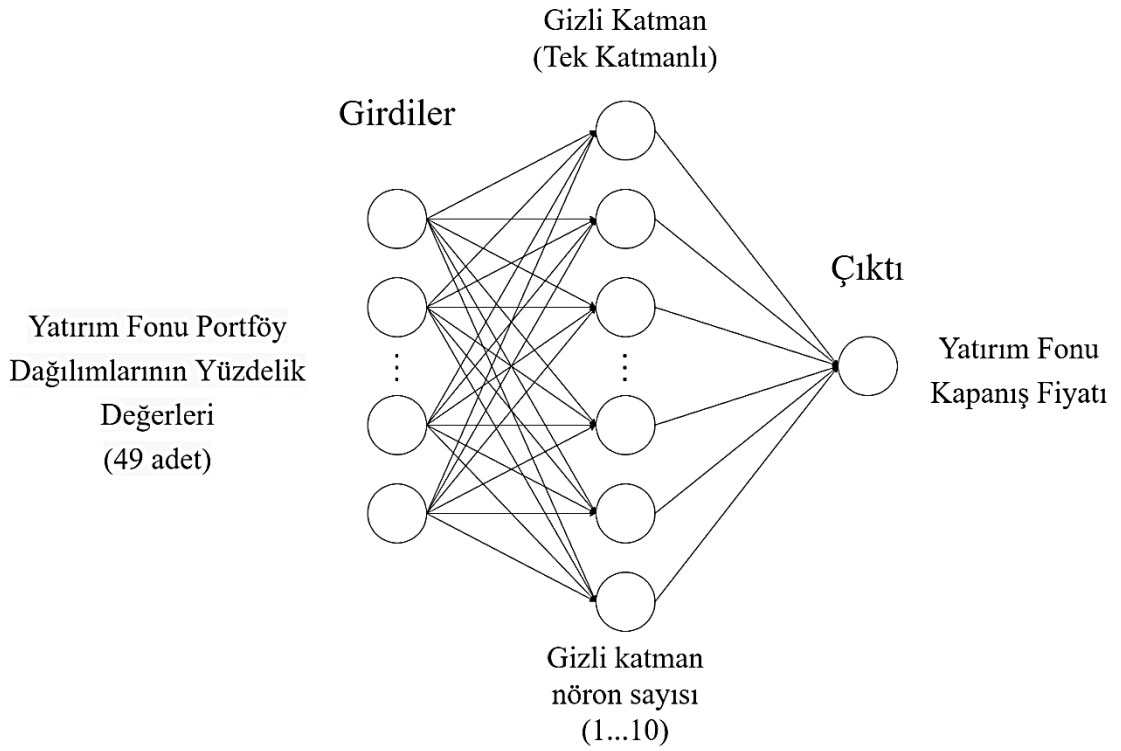
Ağ parametreleri		Eğitim algoritmaları		
		BR	LM	SCG
Girdi sayısı		49	49	49
Çıktı sayısı		1	1	1
Aktivasyon fonksiyonu	Girdi-Gizli	Hiperbolik tanjant sigmoid	Hiperbolik tanjant sigmoid	Hiperbolik tanjant sigmoid
	Gizli-Çıktı	Lineer	Lineer	Lineer
Veri bölme	Eğitim	%85	%70	%70
	Doğrulama	-	%15	%15
	Test	%15	%15	%15
Maksimum eğitim tur sayısı		1000	1000	1000
Performans hedefi		0	0	0
Başlangıç mu değeri		0,005	0,001	-
mu için indirgeme faktörü		0,1	0,1	-
mu için çoğaltma faktörü		10	10	-
mu için maksimum değer		1e10	1e10	-
Maksimum doğrulama hatası		0	6	6
Minimum performans gradyanı		1e-7	1e-7	1e-6
Sigma		-	-	5e-5
Lambda		-	-	5e-7

BR ve LM eğitim algoritmalarında kullanılan mu parametresi, Marquardt düzeltme parametresi olarak isimlendirilmektedir. Mu değeri, performans fonksiyonunun azalmasına yol açan her başarılı yineleme adımından sonra mu için indirgeme faktörü oranında azaltılırken, yalnızca geçici bir adımın performans fonksiyonunu artıracığı durumlarda mu için çoğaltma faktörü oranında artırılmaktadır. İzin verilen maksimum mu değeri ise mu için maksimum değer olarak ifade edilmektedir (Bariani vd., 2004). SCG eğitim algoritmasında kullanılan sigma değeri ikinci türev yaklaşımı için ağırlıktaki değişimi belirlerken lambda parametresi ise Hessian'ın belirsizliğini düzenlemektedir.

İlgili menkul kıymet yatırım fonlarının günlük kapanış fiyatı tahminini yapmak amacıyla girdi olarak fonların 49 kalemden oluşan portföy dağılımlarının yüzdelik değerleri kullanılmıştır. Çıktı ise fonun günlük kapanış fiyatıdır. Tez çalışmasında tek gizli katmanlı ve iki gizli katmanlı YSA'dan faydalanılmıştır.

#### 4.1.1.1. Yatırım fonu kapanış fiyatının fon portföy dağılımından faydalanılarak tahmin edilmesi için geliştirilen tek gizli katmanlı YSA model mimarileri

Çalışmada yatırım fonlarının kapanış fiyatının fon portföy dağılımından faydalanılarak tahmin edilmesi için geliştirilen tek gizli katmanlı YSA mimarisi Şekil 4.2’de gösterilmiştir. Yatırım fonu kapanış fiyatının fon portföy dağılımından faydalanılarak tahmin edilmesi için geliştirilen tek gizli katmanlı YSA model mimarisine örnek olarak 49-2-1 gösterimi verilebilir. Gösterimde 49 sayısını girdi sayısını, 2 sayısını gizli katman nöron sayısını ve 1 sayısını çıktı sayısını temsil etmektedir.



**Şekil 4.2.** Yatırım fonu kapanış fiyatının fon portföy dağılımından faydalanılarak tahmin edilmesi için geliştirilen tek gizli katmanlı YSA model mimarisi

Tek gizli katmanlı YSA modelinin çözümünde üç farklı eğitim algoritması kullanılarak ve gizli katman nöron sayısı 1 ile 10 arasında değiştirilerek her bir fon için toplam 30 farklı ağ yapısı üzerine çalışılmıştır. Bu 30 farklı ağ yapısı için analiz 10 kez tekrarlanmış ve her bir fon için 300 olmak üzere toplam 600 analiz gerçekleştirilmiştir.



Tek gizli katmanlı YSA modeli eğitildikten sonra, modelin tahmininin doğruluğunu değerlendirmek için SSE, MSE, RMSE, MAE, MAPE, R ve R<sup>2</sup> performans ölçütlerinden faydalanılmıştır.

#### 4.1.1.1.1. En fazla sayıda portföye dağılan yatırım fonuna ilişkin bulgular

DBP'nin kapanış fiyatının, fonun portföy dağılımından tahmin edilmesi için geliştirilen tüm tek gizli katmanlı YSA model mimarilerinin eğitimi sonucunda elde edilen performans ölçütlerine ilişkin ortalama, standart sapma, en büyük ve en küçük değerler Çizelge 4.2'de gösterilmiştir.

**Çizelge 4.2.** DBP'nin fon portföy dağılımının tek gizli katmanlı YSA ile eğitimi sonucu elde edilen kapanış fiyatı tahminine ilişkin performans ölçüt değerleri

Performans Ölçütleri		SSE	MSE	RMSE	MAE	MAPE	R	R <sup>2</sup>
BR	Ortalama	5,43E-04	5,66E-07	0,000369	0,000290	0,848043	0,988153	0,987282
	St. Sapma	4,24E-03	4,42E-06	0,000656	0,000589	1,746533	0,104095	0,099065
	En Büyük	4,27E-02	4,45E-05	0,006674	0,005983	17,75600	<b>0,999844</b>	<b>0,999688</b>
	En Küçük	<b>1,33E-05</b>	<b>1,39E-08</b>	<b>0,000118</b>	<b>0,000087</b>	<b>0,254438</b>	-0,047420	0,002249
LM	Ortalama	1,22E-04	1,54E-07	0,000346	0,000264	0,769964	0,998265	0,996538
	St. Sapma	1,49E-04	1,88E-07	0,000186	0,000150	0,441315	0,002116	0,004215
	En Büyük	8,58E-04	1,09E-06	0,001042	0,000834	2,605906	0,999724	0,999448
	En Küçük	1,93E-05	2,44E-08	0,000156	0,000116	0,342332	0,988039	0,976221
SCG	Ortalama	5,02E-04	6,35E-07	0,000773	0,000598	1,758533	0,992823	0,985715
	St. Sapma	2,95E-04	3,74E-07	0,000192	0,000154	0,499488	0,004186	0,008263
	En Büyük	2,18E-03	2,75E-06	0,001659	0,001261	3,824793	0,996717	0,993444
	En Küçük	2,35E-04	2,98E-07	0,000546	0,000414	1,214237	0,968807	0,938586

DBP'nin fon portföy dağılımının tek gizli katmanlı YSA ile eğitimi sonucu elde edilen performans ölçütlerinin tamamı için en iyi değerlere BR eğitim algoritmasına ve 49-8-1 model mimarisine sahip ağda ulaşmıştır.

DBP'nin kapanış fiyatının, fonun portföy dağılımından tahmin edilmesi için geliştirilen tüm tek gizli katmanlı YSA model mimarilerinin doğrulanması sonucunda elde edilen performans ölçütlerine ilişkin ortalama, standart sapma, en büyük ve en küçük değerler Çizelge 4.3'te gösterilmiştir.

**Çizelge 4.3.** DBP'nin fon portföy dağılımının tek gizli katmanlı YSA ile doğrulanması sonucu elde edilen kapanış fiyatı tahminine ilişkin performans ölçüt değerleri

Performans Ölçütleri		SSE	MSE	RMSE	MAE	MAPE	R	R <sup>2</sup>
BR	Ortalama	-	-	-	-	-	-	-
	St. Sapma	-	-	-	-	-	-	-
	En Büyük	-	-	-	-	-	-	-
	En Küçük	-	-	-	-	-	-	-
LM	Ortalama	3,46E-05	2,05E-07	0,000410	0,000291	0,844491	0,997683	0,995378
	St. Sapma	3,94E-05	2,33E-07	0,000192	0,000143	0,420105	0,002702	0,005367
	En Büyük	2,74E-04	1,62E-06	0,001273	0,000784	2,404083	<b>0,999518</b>	<b>0,999037</b>
	En Küçük	<b>7,13E-06</b>	<b>4,22E-08</b>	<b>0,000205</b>	<b>0,000153</b>	<b>0,433067</b>	0,980535	0,961449
SCG	Ortalama	1,47E-04	8,69E-07	0,000829	0,000614	1,796535	0,989981	0,980666
	St. Sapma	3,53E-04	2,09E-06	0,000427	0,000183	0,552942	0,024555	0,042951
	En Büyük	3,60E-03	2,13E-05	0,004616	0,001646	4,455314	0,997167	0,994343
	En Küçük	3,94E-05	2,33E-07	0,000483	0,000376	1,110546	0,749313	0,561471

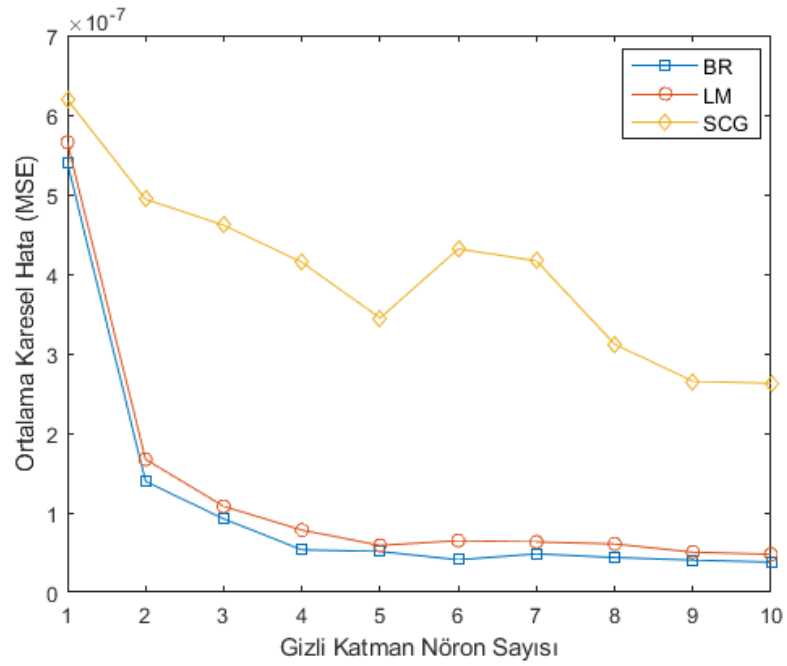
DBP'nin fon portföy dağılımının tek gizli katmanlı YSA ile doğrulanması sonucu elde edilen performans ölçütlerinden MAE ve MAPE hariç tamamı için en iyi değerlere LM eğitim algoritmasına ve 49-7-1 model mimarisine sahip ağda ulaşmıştır. En iyi MAE ve MAPE değerlerine ise 49-9-1 model mimarisine sahip ağda ulaşmıştır.

DBP'nin kapanış fiyatının, fonun portföy dağılımından tahmin edilmesi için geliştirilen tüm tek gizli katmanlı YSA model mimarilerinin test edilmesi sonucunda elde edilen performans ölçütlerine ilişkin ortalama, standart sapma, en büyük ve en küçük değerler Çizelge 4.4'te gösterilmiştir. Geliştirilen tüm tek gizli katmanlı YSA mimarilerinin test edilmesi sonucunda elde edilen en iyi MSE, MAPE ve R performans ölçüt değerlerinin gizli katman nöron sayısına göre değişimi ise sırasıyla Şekil 4.3, Şekil 4.4 ve Şekil 4.5'te gösterilmiştir.


**Çizelge 4.4.** DBP'nin fon portföy dağılımının tek gizli katmanlı YSA ile test edilmesi sonucu elde edilen kapanış fiyatı tahminine ilişkin performans ölçüt değerleri

Performans Ölçütleri		SSE	MSE	RMSE	MAE	MAPE	R	R <sup>2</sup>
BR	Ortalama	1,04E-04	6,15E-07	0,000456	0,000315	0,922834	0,986385	0,985821
	St. Sapma	7,03E-04	4,16E-06	0,000638	0,000569	1,750830	0,113431	0,097275
	En Büyük	7,08E-03	4,19E-05	0,006471	0,005815	17,90650	<b>0,999578</b>	<b>0,999156</b>
	En Küçük	<b>6,41E-06</b>	<b>3,79E-08</b>	<b>0,000195</b>	<b>0,000139</b>	<b>0,407553</b>	-0,141760	0,020097
LM	Ortalama	4,07E-05	2,41E-07	0,000445	0,000301	0,870387	0,997260	0,994536
	St. Sapma	4,12E-05	2,44E-07	0,000206	0,000152	0,451962	0,002864	0,005696
	En Büyük	1,99E-04	1,18E-06	0,001085	0,000880	2,816631	0,999467	0,998935
	En Küçük	8,07E-06	4,78E-08	0,000219	0,000152	0,435066	0,985539	0,971287
SCG	Ortalama	1,38E-04	8,18E-07	0,000849	0,000624	1,826912	0,990606	0,981437
	St. Sapma	1,65E-04	9,75E-07	0,000313	0,000162	0,511831	0,011753	0,022341
	En Büyük	1,57E-03	9,26E-06	0,003043	0,001283	3,923147	0,996875	0,993759
	En Küçük	4,44E-05	2,63E-07	0,000513	0,000392	1,143647	0,888851	0,790057


DBP'nin fon portföy dağılımının tek gizli katmanlı YSA ile test edilmesi sonucu elde edilen performans ölçütlerinden SSE, MSE, RMSE, MAPE, R ve R<sup>2</sup> için en iyi değerlere BR eğitim algoritmasına ve 49-10-1 model mimarisine sahip ağda ulaşılmıştır. En iyi MAE değerineyse BR eğitim algoritmasına ve 49-6-1 model mimarisine sahip ağda ulaşılmıştır. Genel olarak performans ölçüt değerleri incelendiğinde en iyi performansın BR eğitim algoritmasına ve 49-10-1 model mimarisine ait ağda elde edildiği sonucuna varılabilir.



**Şekil 4.3.** Fon portföy dağılımı ile DBP'nin kapanış fiyatının tahmini için geliştirilen her bir tek gizli katmanlı YSA model mimarisi için gerçekleştirilen test iterasyonları sonucunda elde edilen en iyi MSE değerleri



**Şekil 4.4.** Fon portföy dağılımı ile DBP'nin kapanış fiyatının tahmini için geliştirilen her bir tek gizli katmanlı YSA model mimarisi için gerçekleştirilen test iterasyonları sonucunda elde edilen en iyi MAPE değerleri



**Şekil 4.5.** Fon portföy dağılımı ile DBP'nin kapanış fiyatının tahmini için geliştirilen her bir tek gizli katmanlı YSA model mimarisi için gerçekleştirilen test iterasyonları sonucunda elde edilen en iyi R değerleri

49-10-1 model mimarisine sahip tek gizli katmanlı YSA'da eğitim algoritması çeşidine göre elde edilen eğitim, doğrulama ve test performans ölçüt sonuçları sırasıyla Çizelge 4.5, Çizelge 4.6 ve Çizelge 4.7'de gösterilmiştir.

**Çizelge 4.5.** DBP'nin fon portföy dağılımının tek gizli katmanlı YSA ile eğitimi sonucu elde edilen kapanış fiyatı tahminine ilişkin performans ölçüt değerleri (model: 49-10-1)

Performans Ölçütleri	Eğitim Algoritması		
	BR	LM	SCG
SSE	2,33E-05	3,25E-05	2,58E-04
MSE	2,43E-08	4,12E-08	3,27E-07
RMSE	0,000156	0,000203	0,000572
MAE	0,000115	0,000151	0,000427
MAPE	0,336562	0,446763	1,230491
R	0,999725	0,999528	0,996330
R <sup>2</sup>	0,999450	0,999056	0,992673


**Çizelge 4.6.** DBP'nin fon portföy dağılımının tek gizli katmanlı YSA ile doğrulanması sonucu elde edilen kapanış fiyatı tahminine ilişkin performans ölçüt değerleri (model: 49-10-1)

Performans Ölçütleri	Eğitim Algoritması		
	BR	LM	SCG
SSE	-	1,58E-05	5,58E-05
MSE	-	9,37E-08	3,3E-07
RMSE	-	0,000306	0,000575
MAE	-	0,000175	0,000433
MAPE	-	0,513962	1,288894
R	-	0,998996	0,996318
R <sup>2</sup>	-	0,997992	0,992649

**Çizelge 4.7.** DBP'nin fon portföy dağılımının tek gizli katmanlı YSA ile test edilmesi sonucu elde edilen kapanış fiyatı tahminine ilişkin performans ölçüt değerleri (model: 49-10-1)


Performans Ölçütleri	Eğitim Algoritması		
	BR	LM	SCG
SSE	6,41E-06	8,07E-06	4,44E-05
MSE	3,79E-08	4,78E-08	2,63E-07
RMSE	0,000195	0,000219	0,000513
MAE	0,000141	0,000162	0,000402
MAPE	0,407553	0,474173	1,143647
R	0,999578	0,999467	0,996875
R <sup>2</sup>	0,999156	0,998935	0,993759

İlgili model mimarisi Şekil 4.6'da gösterilmiştir.



**Şekil 4.6.** Fon portföy dağılımı ile DBP'nin kapanış fiyatının tahmini için geliştirilen tek gizli katmanlı YSA model mimarisi (eğitim algoritması: BR, model: 49-10-1)

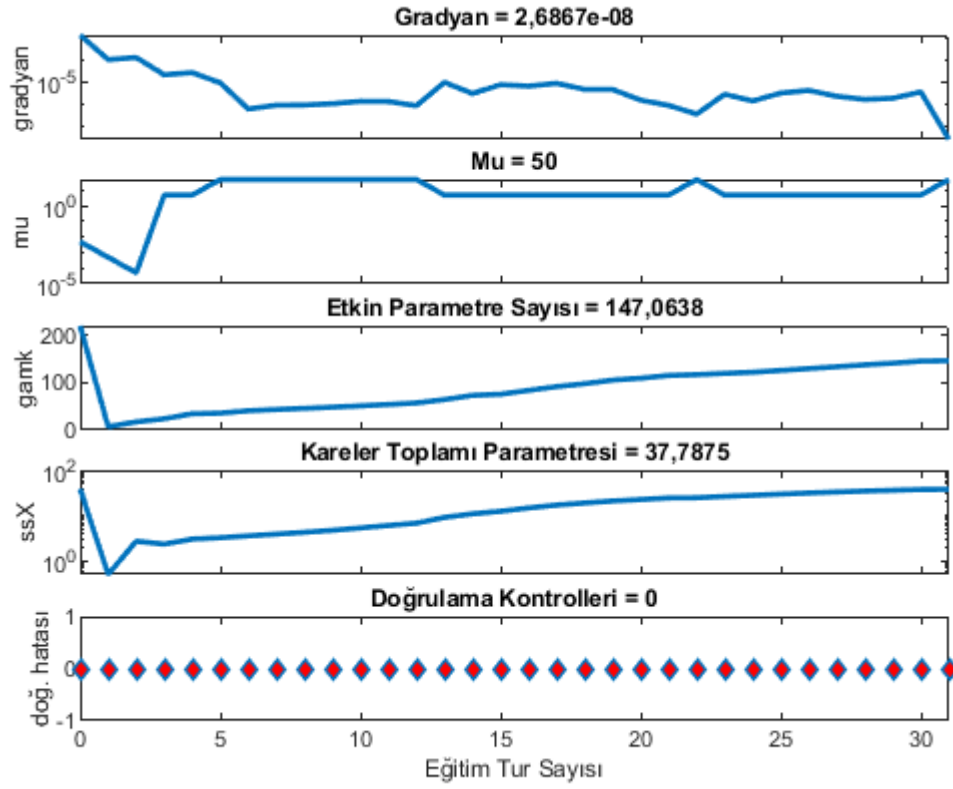
Performans ölçütlerinden MSE'nin eğitim ve test için performansı Şekil 4.7'de gösterilmektedir. Gerçekleştirilen işlem neticesinde, eğitim algoritmasına dair adımlar, eğitim ve test hatasında sürekli bir artıştan sonra durur ve en iyi performans, en düşük eğitim ve test hatası olan eğitim tur sayısından alınır. Dolayısıyla, şekilden en iyi eğitim performansının  $2,4265E-08$  MSE ile 31. eğitim turunda elde edildiği sonucu çıkarılabilir.



**Şekil 4.7.** Fon portföy dağılımı ile DBP'nin kapanış fiyatının tahmin edilmesi için geliştirilen tek gizli katmanlı YSA'nın MSE Performansı (eğitim algoritması: BR, model: 49-10-1)

Şekil 4.8, eğitim durumu grafiklerini göstermektedir. Gradyan grafiği, eğitim tur sayısına göre gradyan katsayısındaki değişimi göstermektedir. 31 sayılı eğitim turunda gradyan katsayısının son değeri  $2,6867E-08$ 'dir ve neredeyse sıfırdır. Bu da hatanın minimum düzeyde olduğu anlamına gelmektedir. Minimum gradyan katsayısına ulaşılması, ağların iyi bir şekilde eğitilmesi, doğrulanması ve test edilmesiyle mümkün olacaktır. Şekilden, gradyan katsayısının eğitim tur sayısındaki artışla azaldığı görülmektedir. Mu grafiğinde elde edilen mu değeri 50'dir. gamk değeri, etkin parametre sayısıdır. Şekildeki gamk grafiğinde etkin parametre sayısı 147,0638 olarak görülmektedir. Bu da tek gizli katmanlı YSA modelinin eğitim sürecinde, sinir ağı alt modelinin yaklaşık 148 parametre içerdiği anlamına gelmektedir. ssX değeri, X'in ortalamasından sapmaların karelerinin toplamı parametresidir. Bu nicelik, bir veri setindeki değerler arasındaki toplam değişimi ölçmektedir. ssX'in değeri ne kadar büyük olursa, veri setindeki değerler arasındaki varyasyon o kadar büyük olur. Şekildeki ssX grafiğinde, ssX fonksiyonunun değeri 37,7875 olarak verilmiştir. Bu değer hataların ağı toplam eğitim sonucu üzerindeki etkisini göstermektedir. Çok sayıda doğrulama hatası, aşırı öğrenmeyi işaret etmektedir. Doğrulama hatası grafiği, kontrol setindeki hata değişimini göstermektedir. Grafikteki doğrulama hatası değeri, doğrulama kontrollerindeki başarısızlıkların sayısıdır. Doğrulama başarısızlıkları, doğrulama ortalama MSE'sini artıran iterasyonlarda görülmektedir. Çalışmada, maksimum doğrulama hatası sayısı 6 olarak ayarlanmıştır. Art arda 6 doğrulama başarısızlığından sonra eğitim otomatik olarak durur. Doğrulama hatası değeri tüm eğitim turları için sıfır olarak bulunmuş ve doğrulama grafiğinde gösterilmiştir (Chanda vd., 2021; Hassan vd., 2019; Muravyova ve Gabitov, 2021; Sharma, 2019; Zitar ve Hussain, 2019).

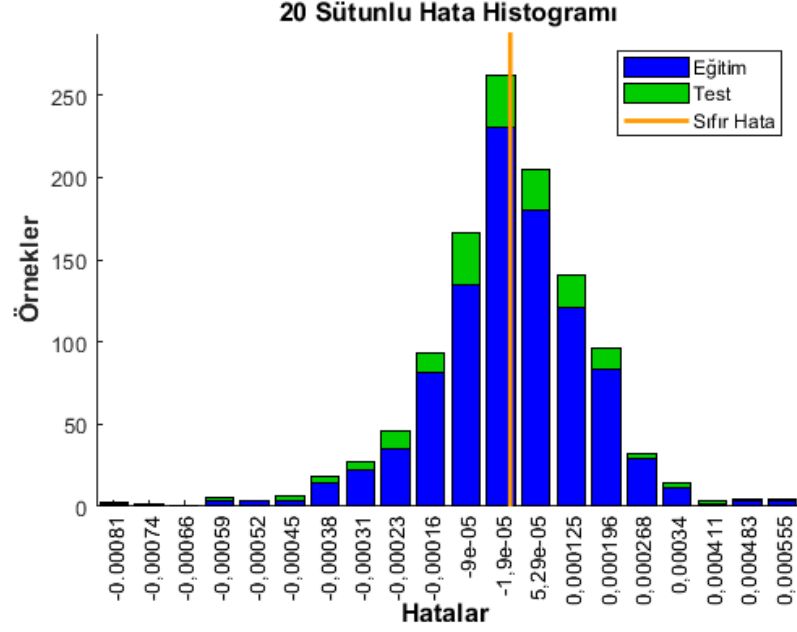




**Şekil 4.8.** Fon portföy dağılımı ile DBP'nin kapanış fiyatının tahmin edilmesi için geliştirilen tek gizli katmanlı YSA'nın eğitim durumu (eğitim algoritması: BR, model: 49-10-1)


Eğitilmiş ağıın eğitim ve test hatalarından oluşan bir hata histogramı Şekil 4.9'da gösterilmiştir. Hata histogramı, bir YSA'yı eğittikten sonra hedef (gerçekleşen) değerler ile tahmin edilen değerler arasındaki hataları gösterir. Şekildeki hata değerleri, tahmin edilen değerlerin hedef değerlerden farklarının ne kadar olduğunu göstermektedir. Bundan dolayı bu değerler negatif değer alabilir (Shahbaz vd., 2020). Şekilde gösterilen hata histogramı, elde edilen veri uydurma hatalarının normal olarak yaklaşık sıfır hata (hedef-çıktı) gibi iyi bir aralıkta dağıldığını göstermektedir. Bölmeler, grafikte gösterilen dikey çubukların sayısını temsil etmekte olup toplam hata aralığı 20 küçük bölme bölünmüştür. Hataların dağıtımı, eğitilmiş ağıın kalitesinin değerlendirilmesi için de kullanılabilir. Şekil incelendiğinde hataların çoğunun  $\pm 0,0006$  aralığında olduğu ve maksimum hatanın yaklaşık olarak 0,001 olduğu tespit edilebilir. Ayrıca sıfır hata noktası  $-1,9E-05$  merkezli tanımlanmış bölmenin altına düşmektedir. Bu nedenle, elde

edilen hataya bağı olarak, eğitimli ağ, yatırım fonu kapanış fiyatının tahmini için gönül rahatlığıyla kullanılabilir.



**Şekil 4.9.** Fon portföy dağılımı ile DBP'nin kapanış fiyatının tahmin edilmesi için geliştirilen tek gizli katmanlı YSA'nın hata histogramı (eğitim algoritması: BR, model: 49-10-1)

Ağın gerçekleşen değerler ve tahmin edilen değerler arasındaki regresyon grafiği Şekil 4.10'da gösterilmiştir. Şekilde görüldüğü üzere YSA modelinin eğitim ve test için korelasyon katsayısı değerleri sırasıyla 0,99972 ve 0,99958'e eşittir. Bununla beraber tüm veriler için elde edilen korelasyon katsayısı değerinin 0,9997 olması, elde edilen tahmin modelinin çıktılarının gerçekleşen çıktı değerleriyle uyum içinde olduğu ve bu değerler arasında sapma olmadığı anlamına gelmektedir.



**Şekil 4.10.** Fon portföy dağılımı ile DBP'nin kapanış fiyatının tahmin edilmesi için geliştirilen tek gizli katmanlı YSA'nın regresyon grafikleri (eğitim algoritması: BR, model: 49-10-1)

#### 4.1.1.1.2. En çok işlem gören yatırım fonuna ilişkin bulgular

IST'nin kapanış fiyatının, fonun portföy dağılımından tahmin edilmesi için geliştirilen tüm tek gizli katmanlı YSA model mimarilerinin eğitimi sonucunda elde edilen performans ölçütlerine ilişkin ortalama, standart sapma, en büyük ve en küçük değerler Çizelge 4.8'de gösterilmiştir.

**Çizelge 4.8.** IST'nin fon portföy dağılımının tek gizli katmanlı YSA ile eğitimi sonucu elde edilen kapanış fiyatı tahminine ilişkin performans ölçüt değerleri

Performans Ölçütleri		SSE	MSE	RMSE	MAE	MAPE	R	R <sup>2</sup>
BR	Ortalama	0,000887	9,25E-07	0,000940	0,000667	2,985001	0,982906	0,966174
	St. Sapma	0,000433	4,51E-07	0,000206	0,000174	0,718146	0,008437	0,016461
	En Büyük	0,002196	2,29E-06	0,001513	0,001152	4,934379	0,990894	0,981871
	En Küçük	0,000477	4,98E-07	0,000706	0,000469	2,126379	0,956481	0,914856
LM	Ortalama	0,000812	1,03E-06	0,000992	0,000707	3,157687	0,980944	0,962325
	St. Sapma	0,000356	4,51E-07	0,000209	0,000171	0,714343	0,008597	0,016783
	En Büyük	0,001666	2,11E-06	0,001452	0,001119	4,834165	<b>0,991569</b>	<b>0,983210</b>
	En Küçük	<b>0,000367</b>	<b>4,64E-07</b>	<b>0,000681</b>	<b>0,000469</b>	<b>2,085689</b>	0,960279	0,922137
SCG	Ortalama	0,002167	2,74E-06	0,001516	0,001179	5,086277	0,936281	0,901658
	St. Sapma	0,003454	4,37E-06	0,000667	0,000636	2,621622	0,158229	0,14995
	En Büyük	0,022054	2,79E-05	0,005284	0,004793	19,97401	0,977617	0,955736
	En Küçük	0,000977	1,24E-06	0,001112	0,000802	3,556595	-0,113570	0,005270

IST'nin fon portföy dağılımının tek gizli katmanlı YSA ile eğitimi sonucu elde edilen performans ölçütlerinin tamamı için en iyi değerlere LM eğitim algoritmasına ve 49-5-1 model mimarisine sahip ağda ulaşılmıştır.

IST'nin kapanış fiyatının, fonun portföy dağılımından tahmin edilmesi için geliştirilen tüm tek gizli katmanlı YSA model mimarilerinin doğrulanması sonucunda elde edilen performans ölçütlerine ilişkin ortalama, standart sapma, en büyük ve en küçük değerler Çizelge 4.9'da gösterilmiştir.

**Çizelge 4.9.** IST'nin fon portföy dağılımının tek gizli katmanlı YSA ile doğrulanması sonucu elde edilen kapanış fiyatı tahminine ilişkin performans ölçüt değerleri

Performans Ölçütleri		SSE	MSE	RMSE	MAE	MAPE	R	R <sup>2</sup>
BR	Ortalama	-	-	-	-	-	-	-
	St. Sapma	-	-	-	-	-	-	-
	En Büyük	-	-	-	-	-	-	-
	En Küçük	-	-	-	-	-	-	-
LM	Ortalama	1,94E-04	1,15E-06	0,001048	0,000750	3,342509	0,979144	0,958803
	St. Sapma	8,43E-05	4,99E-07	0,000219	0,000174	0,756558	0,008998	0,017512
	En Büyük	4,84E-04	2,86E-06	0,001692	0,001220	5,503153	<b>0,991251</b>	<b>0,982578</b>
	En Küçük	<b>7,33E-05</b>	<b>4,34E-07</b>	<b>0,000659</b>	<b>0,000477</b>	<b>2,081054</b>	0,942461	0,888233
SCG	Ortalama	4,61E-04	2,73E-06	0,001510	0,001174	5,058591	0,935271	0,901925
	St. Sapma	7,37E-04	4,36E-06	0,000668	0,000632	2,596527	0,164906	0,149491
	En Büyük	4,71E-03	2,79E-05	0,005281	0,004765	19,89162	0,979289	0,959006
	En Küçük	2,06E-04	1,22E-06	0,001103	0,000828	3,646232	-0,187600	0,007537

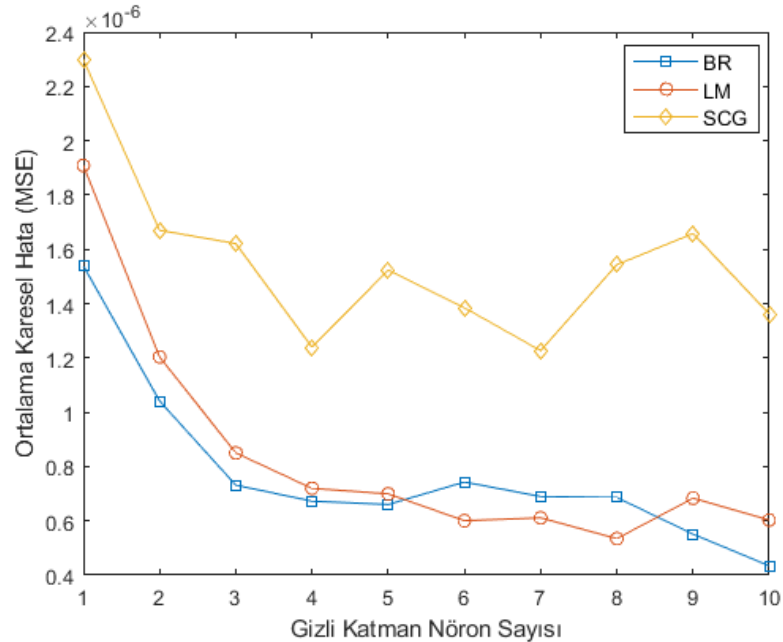
IST'nin fon portföy dağılımının tek gizli katmanlı YSA ile doğrulanması sonucu elde edilen performans ölçütlerinden tamamı için en iyi değerlere LM eğitim algoritmasına ve 49-10-1 model mimarisine sahip ağda ulaşılmıştır.

IST'nin kapanış fiyatının, fonun portföy dağılımından tahmin edilmesi için geliştirilen tüm tek gizli katmanlı YSA model mimarilerinin test edilmesi sonucunda elde edilen performans ölçütlerine ilişkin ortalama, standart sapma, en büyük ve en küçük değerler Çizelge 4.10'da gösterilmiştir. Geliştirilen tüm tek gizli katmanlı YSA mimarilerinin test edilmesi sonucunda elde edilen en iyi MSE, MAPE ve R performans ölçüt değerlerinin gizli katman nöron sayısına göre değişimi ise sırasıyla Şekil 4.11, Şekil 4.12 ve Şekil 4.13'te gösterilmiştir.

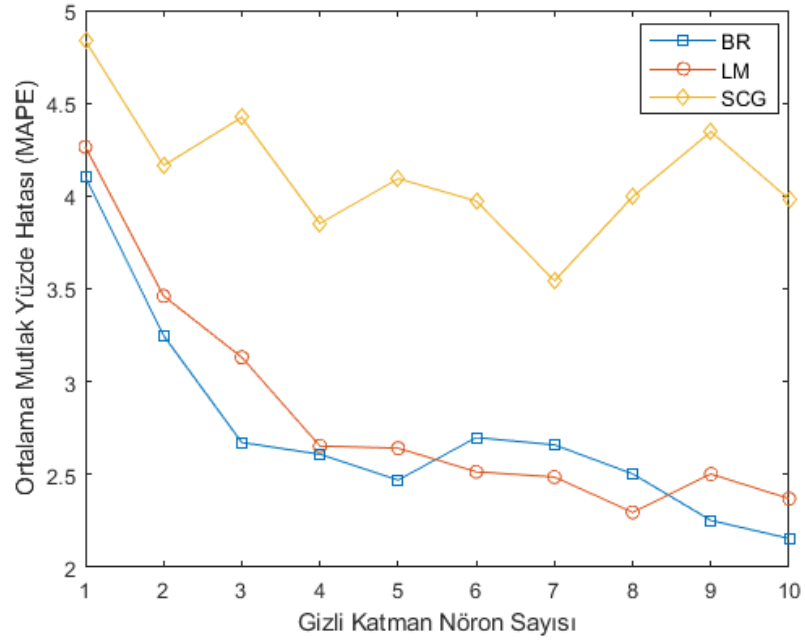
**Çizelge 4.10.** IST'nin fon portföy dağılımının tek gizli katmanlı YSA ile test edilmesi sonucu elde edilen kapanış fiyatı tahminine ilişkin performans ölçüt değerleri

Performans Ölçütleri		SSE	MSE	RMSE	MAE	MAPE	R	R <sup>2</sup>
BR	Ortalama	4,25E-04	2,52E-06	0,001161	0,000729	3,214574	0,973231	0,949669
	St. Sapma	2,19E-03	1,29E-05	0,001082	0,000183	0,716703	0,049901	0,076299
	En Büyük	2,21E-02	1,31E-04	0,011430	0,001417	5,468969	<b>0,991368</b>	<b>0,982811</b>
	En Küçük	<b>7,34E-05</b>	<b>4,34E-07</b>	<b>0,000659</b>	<b>0,000481</b>	<b>2,155167</b>	0,503787	0,253802
LM	Ortalama	3,75E-04	2,22E-06	0,001174	0,000763	3,368835	0,973302	0,949203
	St. Sapma	1,69E-03	9,99E-06	0,000918	0,000166	0,667540	0,043437	0,067211
	En Büyük	1,72E-02	1,01E-04	0,010074	0,001438	5,253436	0,990573	0,981235
	En Küçük	9,03E-05	5,34E-07	0,000731	0,000518	2,296140	0,550078	0,302586
SCG	Ortalama	4,76E-04	2,81E-06	0,001545	0,001200	5,163888	0,933387	0,897833
	St. Sapma	7,11E-04	4,21E-06	0,000652	0,000610	2,568862	0,163161	0,149102
	En Büyük	4,89E-03	2,90E-05	0,005381	0,004859	21,00218	0,977198	0,954916
	En Küçük	2,07E-04	1,23E-06	0,001108	0,000800	3,542859	-0,177150	0,006328

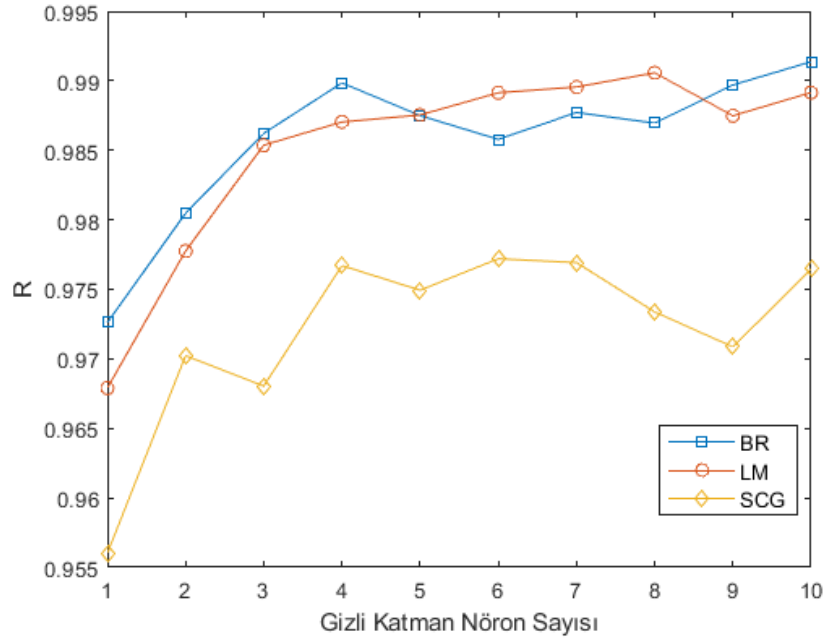
IST'nin fon portföy dağılımının tek gizli katmanlı YSA ile test edilmesi sonucu elde edilen performans ölçütlerinin tamamı için en iyi değerlere BR eğitim algoritmasına ve 49-10-1 model mimarisine sahip ağda ulaşılmıştır.



**Şekil 4.11.** Fon portföy dağılımı ile IST'nin kapanış fiyatının tahmini için geliştirilen her bir tek gizli katmanlı YSA model mimarisine için gerçekleştirilen test iterasyonları sonucunda elde edilen en iyi MSE değerleri



**Şekil 4.12.** Fon portföy dağılımı ile IST'nin kapanış fiyatının tahmini için geliştirilen her bir tek gizli katmanlı YSA model mimarisi için gerçekleştirilen test iterasyonları sonucunda elde edilen en iyi MAPE değerleri



**Şekil 4.13.** Fon portföy dağılımı ile IST'nin kapanış fiyatının tahmini için geliştirilen her bir tek gizli katmanlı YSA model mimarisi için gerçekleştirilen test iterasyonları sonucunda elde edilen en iyi R değerleri

49-10-1 model mimarisine sahip tek gizli katmanlı YSA’da eğitim algoritması çeşidine göre elde edilen eğitim, doğrulama ve test performans ölçüt sonuçları sırasıyla Çizelge 4.11, Çizelge 4.12 ve Çizelge 4.13’de gösterilmiştir.

**Çizelge 4.11.** IST’nin fon portföy dağılımının tek gizli katmanlı YSA ile eğitimi sonucu elde edilen kapanış fiyatı tahminine ilişkin performans ölçüt değerleri (model: 49-10-1)

Performans Ölçütleri	Eğitim Algoritması		
	BR	LM	SCG
SSE	0,000637	0,000523	0,001320
MSE	6,65E-07	6,62E-07	1,67E-06
RMSE	0,000815	0,000813	0,001293
MAE	0,000551	0,000538	0,000981
MAPE	2,514137	2,508091	4,247148
R	0,987936	0,987899	0,968490
R <sup>2</sup>	0,976017	0,975945	0,937972

**Çizelge 4.12.** IST’nin fon portföy dağılımının tek gizli katmanlı YSA ile doğrulanması sonucu elde edilen kapanış fiyatı tahminine ilişkin performans ölçüt değerleri (model: 49-10-1)


Performans Ölçütleri	Eğitim Algoritması		
	BR	LM	SCG
SSE	-	0,000104	0,000247
MSE	-	6,12E-07	1,46E-06
RMSE	-	0,000783	0,001209
MAE	-	0,000554	0,000959
MAPE	-	2,441702	4,219125
R	-	0,988038	0,973411
R <sup>2</sup>	-	0,976218	0,947529



**Çizelge 4.13.** IST'nin fon portföy dağılımının tek gizli katmanlı YSA ile test edilmesi sonucu elde edilen kapanış fiyatı tahminine ilişkin performans ölçüt değerleri (model: 49-10-1)

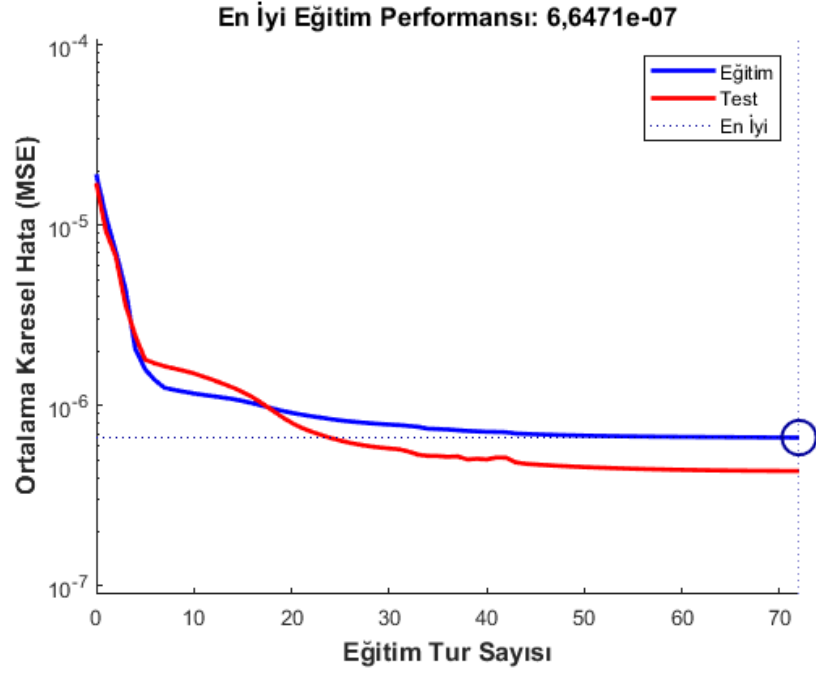
Performans Ölçütleri	Eğitim Algoritması		
	BR	LM	SCG
SSE	7,34E-05	1,02E-04	2,30E-04
MSE	4,34E-07	6,03E-07	1,36E-06
RMSE	0,000659	0,000776	0,001167
MAE	0,000481	0,000543	0,000906
MAPE	2,155167	2,369743	3,982895
R	0,991368	0,989153	0,976470
R <sup>2</sup>	0,982811	0,978424	0,953493

İlgili model mimarisi Şekil 4.14'te gösterilmiştir.



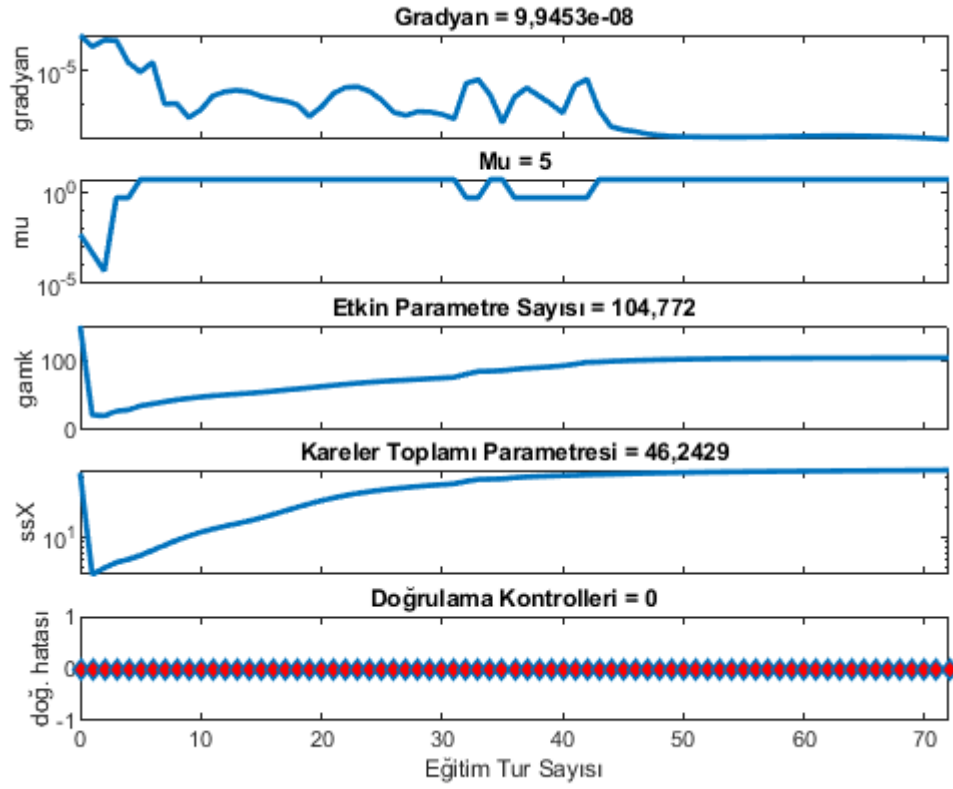
**Şekil 4.14.** Fon portföy dağılımı ile IST'nin kapanış fiyatının tahmini için geliştirilen tek gizli katmanlı YSA model mimarisi (eğitim algoritması: BR, model: 49-10-1)

Performans ölçütlerinden MSE'nin eğitim ve test için performansı Şekil 4.15'te gösterilmektedir. Şekilden en iyi eğitim performansının 6,6471E-07 MSE ile 72. eğitim turunda elde edildiği sonucu çıkarılabilir.



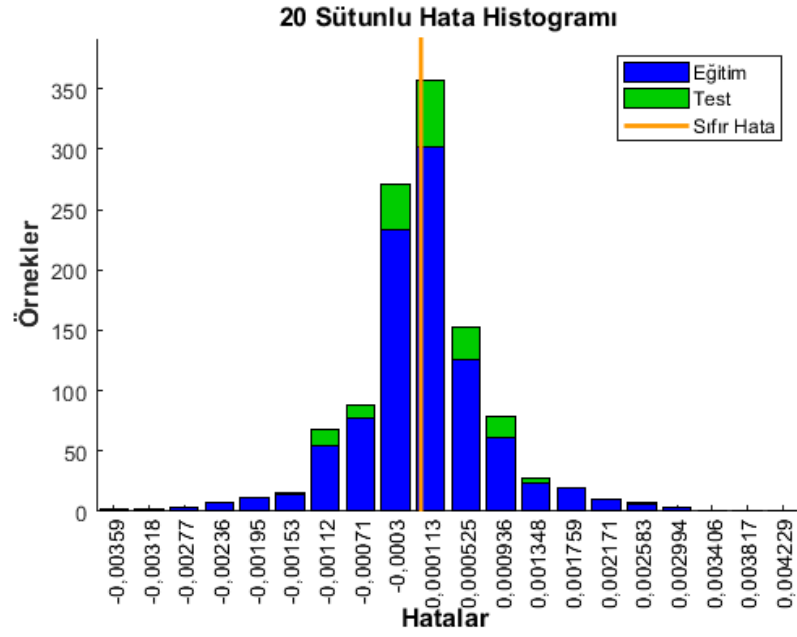
**Şekil 4.15.** Fon portföy dağılımı ile IST'nin kapanış fiyatının tahmini için geliştirilen tek gizli katmanlı YSA'nın MSE Performansı (eğitim algoritması: BR, model: 49-10-1)

Şekil 4.16, eğitim tur sayısına göre gradyan katsayısındaki değişimi göstermektedir. 72 numaralı eğitim turunda gradyan katsayısının son değeri yaklaşık olarak sıfıra yakın olan  $9,9453E-08$ 'dir. Minimum gradyan katsayısı değeri ağların eğitilmesi ve test edilmesi ile daha iyi olmaktadır. Şekilden, gradyan değerinin eğitim tur sayısındaki artışla azaldığı görülmektedir. Mu değeri, sinir ağını eğitmek için kullanılan algoritmanın kontrol parametresidir ve mu değeri 5'tir. "Şekildeki gamk grafiğinde etkin parametre sayısı 104,772 olarak görülmektedir. Bu da tek gizli katmanlı YSA modelinin eğitim sürecinde, sinir ağı alt modelinin yaklaşık 105 parametre içerdiği anlamına gelmektedir. Şekildeki ssX grafiğinde, kareler toplamı parametresini ifade eden ssX fonksiyonunun değeri 46,2429 olarak verilmiştir. Doğrulama hatası grafiği, kontrol setindeki hata değişimini göstermektedir. Grafikteki doğrulama hatası değeri, tüm eğitim turları için sıfırdır.




**Şekil 4.16.** Fon portföy dağılımı ile IST'nin kapanış fiyatının tahmini için geliştirilen tek gizli katmanlı YSA'nın eğitim durumu (eğitim algoritması: BR, model: 49-10-1)

Eğitilmiş ağıın eğitim, doğrulama ve test hatalarından oluşan bir hata histogramı Şekil 4.17'de gösterilmiştir. Şekilde gösterilen hata histogramı, elde edilen veri uydurma hatalarının normal olarak yaklaşık sıfır hata (hedef-çıktı) gibi iyi bir aralıkta dağıtıldığını göstermektedir. Şekil incelendiğinde hataların çoğunun  $\pm 0,0025$  aralığında olduğu ve maksimum hatanın yaklaşık olarak 0,004 olduğu tespit edilebilir. Ayrıca sıfır hata noktası -0,0003 merkezli tanımlanmış bölmenin altına düşmektedir. Bu nedenle, elde edilen hataya bağlı olarak, eğitilmiş ağı, yatırım fonu kapanış fiyatının tahmini için gönül rahatlığıyla kullanılabilir.



**Şekil 4.17.** Fon portföy dağılımı ile IST'nin kapanış fiyatının tahmini için geliştirilen tek gizli katmanlı YSA'nın hata histogramı (eğitim algoritması: BR, model: 49-10-1)

Ağın gerçekleşen değerler ile tahmin edilen değerler arasındaki regresyon grafiği Şekil 4.18'de gösterilmiştir. Şekilde görüldüğü üzere YSA modelinin eğitim ve test için korelasyon katsayısı değerleri sırasıyla 0,98794 ve 0,99137'dir. Ayrıca tüm veriler için elde edilen korelasyon katsayısı değerinin 0,9884 olması, elde edilen tahmin modelinin çıktılarının gerçekleşen çıktı değerleriyle uyum içinde olduğu ve bu değerler arasında sapma olmadığı anlamına gelmektedir.

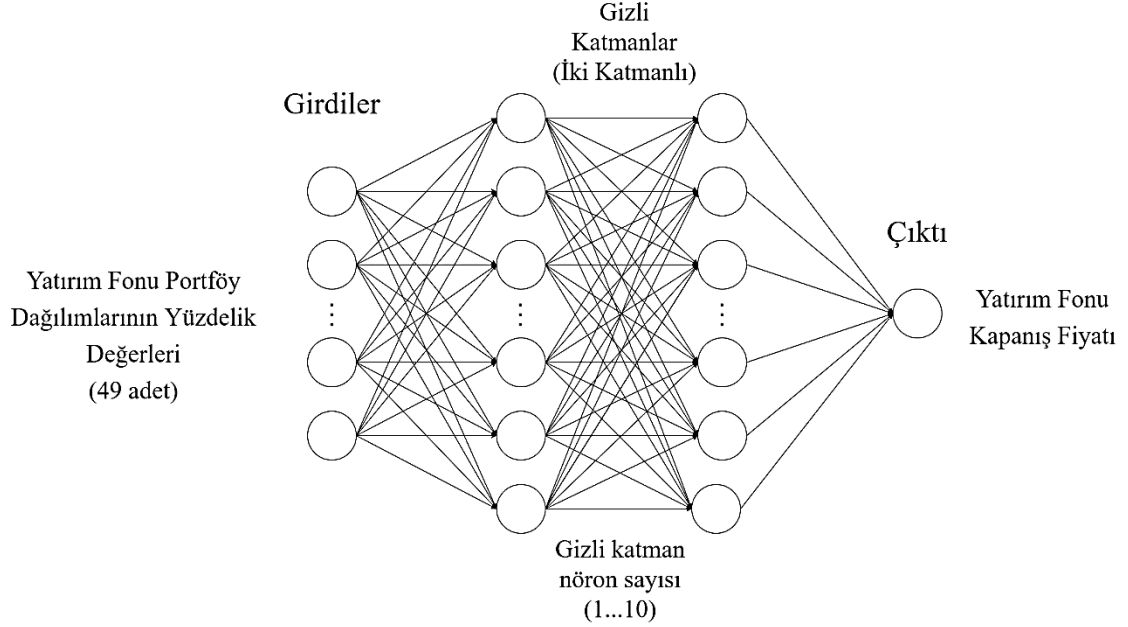


**Şekil 4.18.** Fon portföy dağılımı ile IST'nin kapanış fiyatının tahmini için geliştirilen tek gizli katmanlı YSA'nın regresyon grafikleri (eğitim algoritması: BR, model: 49-10-1)

#### 4.1.1.2. Yatırım fonu kapanış fiyatının fon portföy dağılımından faydalanılarak tahmin edilmesi için geliştirilen iki gizli katmanlı YSA model mimarileri

Çalışmada inceleme altına alınacak yatırım fonlarının kapanış fiyatının fon portföy dağılımından faydalanılarak tahmin edilmesi için geliştirilen iki gizli katmanlı YSA mimarisi Şekil 4.19'da gösterilmiştir. Yatırım fonu kapanış fiyatının fon portföy dağılımından faydalanılarak tahmin edilmesi için geliştirilen iki gizli katmanlı YSA model mimarisine örnek olarak 49-2-3-1 gösterimi verilebilir. Gösterimde 49 sayısı girdi

sayısını, 2 sayısı ilk gizli katmanın nöron sayısını, 3 sayısı ikinci gizli katmanın nöron sayısını ve 1 sayısı çıktı sayısını temsil etmektedir.



**Şekil 4.19.** Yatırım fonu kapanış fiyatının fon portföy dağılımından faydalanılarak tahmin edilmesi için geliştirilen iki gizli katmanlı YSA model mimarisi

İki gizli katmanlı YSA modelinin çözümünde, üç farklı eğitim algoritması kullanılarak, birinci gizli katman nöron sayısı ve ikinci gizli katman nöron sayısı 1 ile 10 arasında değişecek şekilde her bir fon için toplamda 300 farklı ağ yapısı üzerine çalışılmıştır. Bu 300 farklı ağ yapısı için analizler onar defa tekrarlanmış ve her bir fon için 3000 olmak üzere toplam 6000 analiz gerçekleştirilmiştir.

İki gizli katmanlı YSA modelini eğittikten sonra, modelin tahmininin doğruluğunu değerlendirmek için SSE, MSE, RMSE, MAE, MAPE, R ve  $R^2$  performans ölçütlerinden faydalanılmıştır.

#### 4.1.1.2.1. En fazla sayıda portföye dağılan yatırıma fonuna ilişkin bulgular

DBP'nin kapanış fiyatının, fonun portföy dağılımından tahmin edilmesi için geliştirilen tüm iki gizli katmanlı YSA model mimarilerinin eğitimi sonucunda elde edilen

performans ölçütlerine ilişkin ortalama, standart sapma, en büyük ve en küçük değerler Çizelge 4.14'te gösterilmiştir.

**Çizelge 4.14.** DBP'nin fon portföy dağılımının iki gizli katmanlı YSA ile eğitimi sonucu elde edilen kapanış fiyatı tahminine ilişkin performans ölçüt değerleri

Performans Ölçütleri		SSE	MSE	RMSE	MAE	MAPE	R	R <sup>2</sup>
BR	Ortalama	2,17E-04	2,27E-07	0,000315	0,000238	0,695795	0,998289	0,996602
	St. Sapma	1,92E-03	2,00E-06	0,000357	0,000303	0,897250	0,004634	0,009040
	En Büyük	4,28E-02	4,46E-05	0,006678	0,005990	17,78293	<b>0,999915</b>	<b>0,999830</b>
	En Küçük	<b>7,37E-06</b>	<b>7,69E-09</b>	<b>0,0000877</b>	<b>0,000066</b>	<b>0,197032</b>	0,930813	0,866413
LM	Ortalama	3,08E-04	3,90E-07	0,000379	0,000287	0,839442	0,994076	0,991490
	St. Sapma	2,23E-03	2,82E-06	0,000496	0,000417	1,235687	0,057473	0,059658
	En Büyük	3,48E-02	4,41E-05	0,006639	0,005969	17,74554	0,999847	0,999694
	En Küçük	1,07E-05	1,36E-08	0,000116	0,0000872	0,255925	-0,205530	0,000459
SCG	Ortalama	1,31E-03	1,65E-06	0,000933	0,000720	2,111897	0,970654	0,963317
	St. Sapma	4,81E-03	6,09E-06	0,000884	0,000786	2,340066	0,145424	0,133362
	En Büyük	3,58E-02	4,54E-05	0,006735	0,006039	18,44165	0,997891	0,995786
	En Küçük	1,46E-04	1,85E-07	0,000430	0,000324	0,939922	-0,342620	1,78E-05

DBP'nin fon portföy dağılımının iki gizli katmanlı YSA ile eğitimi sonucu elde edilen performans ölçütlerinin tamamı için en iyi değerlere BR eğitim algoritmasına ve 49-10-6-1 model mimarisine sahip ağda ulaşılmıştır.

DBP'nin kapanış fiyatının, fonun portföy dağılımından tahmin edilmesi için geliştirilen tüm iki gizli katmanlı YSA model mimarilerinin doğrulanması sonucunda elde edilen performans ölçütlerine ilişkin ortalama, standart sapma, en büyük ve en küçük değerler Çizelge 4.15'te gösterilmiştir.

**Çizelge 4.15.** DBP'nin fon portföy dağılımının iki gizli katmanlı YSA ile doğrulanması sonucu elde edilen kapanış fiyatı tahminine ilişkin performans ölçüt değerleri

Performans Ölçütleri		SSE	MSE	RMSE	MAE	MAPE	R	R <sup>2</sup>
BR	Ortalama	-	-	-	-	-	-	-
	St. Sapma	-	-	-	-	-	-	-
	En Büyük	-	-	-	-	-	-	-
	En Küçük	-	-	-	-	-	-	-
LM	Ortalama	8,37E-05	4,95E-07	0,000465	0,000320	0,929365	0,993173	0,989471
	St. Sapma	5,05E-04	2,99E-06	0,000529	0,000430	1,261553	0,055482	0,059429
	En Büyük	7,91E-03	4,68E-05	0,006839	0,006231	18,02201	<b>0,999772</b>	<b>0,999543</b>
	En Küçük	<b>3,54E-06</b>	<b>2,09E-08</b>	<b>0,000145</b>	<b>0,000106</b>	<b>0,311505</b>	-0,164130	1,31E-05
SCG	Ortalama	2,90E-04	1,71E-06	0,000967	0,000731	2,139398	0,969319	0,961768
	St. Sapma	1,02E-03	6,01E-06	0,000883	0,000775	2,296707	0,148960	0,132055
	En Büyük	8,12E-03	4,80E-05	0,006931	0,006242	18,62503	0,998225	0,996453
	En Küçük	2,60E-05	1,54E-07	0,000392	0,000306	0,894564	-0,486620	0,000278

DBP'nin fon portföy dağılımının iki gizli katmanlı YSA ile doğrulanması sonucu elde edilen performans ölçütlerinden MAE, R ve R<sup>2</sup> için en iyi değerlere LM eğitim algoritmasına ve 49-9-9-1 model mimarisine sahip ağda ulaşılmıştır. SSE, MSE ve RMSE performans ölçütlerinin en iyi değerlerine LM eğitim algoritmasına ve 49-10-5-1 model mimarisine sahip ağda, MAPE performans ölçütünün en iyi değerine ise LM eğitim algoritmasına ve 49-9-8-1 model mimarisine sahip ağda ulaşılmıştır.


DBP'nin kapanış fiyatının, fonun portföy dağılımından tahmin edilmesi için geliştirilen tüm iki gizli katmanlı YSA model mimarilerinin test edilmesi sonucunda elde edilen performans ölçütlerine ilişkin ortalama, standart sapma, en büyük ve en küçük değerler Çizelge 4.16'da gösterilmiştir. Geliştirilen tüm iki gizli katmanlı YSA mimarilerinin test edilmesi sonucunda elde edilen en iyi MSE, MAPE ve R performans ölçüt değerlerinin birinci gizli katman nöron sayısı – ikinci gizli katman nöron sayısı çiftine göre değişimi ise sırasıyla Şekil 4.20, Şekil 4.21 ve Şekil 4.22'de gösterilmiştir.




**Çizelge 4.16.** DBP'nin fon portföy dağılımının iki gizli katmanlı YSA ile test edilmesi sonucu elde edilen kapanış fiyatı tahminine ilişkin performans ölçüt değerleri

Performans Ölçütleri		SSE	MSE	RMSE	MAE	MAPE	R	R <sup>2</sup>
BR	Ortalama	5,99E-05	3,55E-07	0,000426	0,000272	0,787872	0,996875	0,993850
	St.Sapma	3,54E-04	2,09E-06	0,000416	0,000303	0,921508	0,009529	0,018044
	En Büyük	7,54E-03	4,46E-05	0,006678	0,006079	18,98166	<b>0,999787</b>	<b>0,999573</b>
	En Küçük	<b>3,02E-06</b>	<b>1,79E-08</b>	<b>0,000134</b>	<b>0,0000969</b>	<b>0,280547</b>	0,828341	0,686149
LM	Ortalama	8,94E-05	5,29E-07	0,000496	0,000324	0,940266	0,992746	0,988542
	St.Sapma	4,98E-04	2,95E-06	0,000532	0,000420	1,229034	0,054741	0,059823
	En Büyük	8,10E-03	4,79E-05	0,006921	0,006212	18,15609	0,999707	0,999415
	En Küçük	4,34E-06	2,57E-08	0,000160	0,000112	0,332745	-0,212830	0,020847
SCG	Ortalama	3,05E-04	1,81E-06	0,000999	0,000749	2,192411	0,969003	0,960926
	St.Sapma	1,05E-03	6,20E-06	0,000900	0,000793	2,372114	0,148188	0,129698
	En Büyük	8,78E-03	5,20E-05	0,007209	0,006527	20,59865	0,998029	0,996061
	En Küçük	2,95E-05	1,75E-07	0,000418	0,000320	0,932443	-0,500370	0,004438


DBP'nin fon portföy dağılımının iki gizli katmanlı YSA ile test edilmesi sonucu elde edilen performans ölçütlerinden tamamı için en iyi değerlere BR eğitim algoritmasına ve 49-5-10-1 model mimarisine sahip ağda ulaşılmıştır.



**Şekil 4.20.** Fon portföy dağılımı ile DBP'nin kapanış fiyatının tahmini için geliştirilen her bir iki gizli katmanlı YSA model mimarisine için gerçekleştirilen test iterasyonları sonucunda elde edilen en iyi MSE değerleri



**Şekil 4.21.** Fon portföy dağılımı ile DBP'nin kapanış fiyatının tahmini için geliştirilen her bir iki gizli katmanlı YSA model mimarisi için gerçekleştirilen test iterasyonları sonucunda elde edilen en iyi MAPE değerleri



**Şekil 4.22.** Fon portföy dağılımı ile DBP'nin kapanış fiyatının tahmini için geliştirilen her bir iki gizli katmanlı YSA model mimarisi için gerçekleştirilen test iterasyonları sonucunda elde edilen en iyi R değerleri

49-5-10-1 model mimarisine sahip iki gizli katmanlı YSA’da eğitim algoritması çeşidine göre elde edilen eğitim, doğrulama ve test performans ölçüt sonuçları sırasıyla Çizelge 4.17, Çizelge 4.18 ve Çizelge 4.19’da gösterilmiştir.

**Çizelge 4.17.** DBP’nin fon portföy dağılımının iki gizli katmanlı YSA ile eğitimi sonucu elde edilen kapanış fiyatı tahminine ilişkin performans ölçüt değerleri (model: 49-5-10-1)

Performans Ölçütleri	Eğitim Algoritması		
	BR	LM	SCG
SSE	1,60E-05	3,62E-05	3,15E-04
MSE	1,67E-08	4,58E-08	3,98E-07
RMSE	0,000129	0,000214	0,000631
MAE	0,0000943	0,000159	0,000401
MAPE	0,276767	0,469483	1,149692
R	0,999813	0,999482	0,995499
R <sup>2</sup>	0,999626	0,998965	0,991018

**Çizelge 4.18.** DBP’nin fon portföy dağılımının iki gizli katmanlı YSA ile doğrulanması sonucu elde edilen kapanış fiyatı tahminine ilişkin performans ölçüt değerleri (model: 49-5-10-1)

Performans Ölçütleri	Eğitim Algoritması		
	BR	LM	SCG
SSE	-	1,02E-05	9,62E-05
MSE	-	6,05E-08	5,69E-07
RMSE	-	0,000246	0,000755
MAE	-	0,000173	0,000419
MAPE	-	0,503351	1,157387
R	-	0,999303	0,993623
R <sup>2</sup>	-	0,998607	0,987287

**Çizelge 4.19.** DBP'nin fon portföy dağılımının iki gizli katmanlı YSA ile test edilmesi sonucu elde edilen kapanış fiyatı tahminine ilişkin performans ölçüt değerleri (model: 49-5-10-1)


Performans Ölçütleri	Eğitim Algoritması		
	BR	LM	SCG
SSE	3,02E-06	8,42E-06	4,00E-05
MSE	1,79E-08	4,98E-08	2,37E-07
RMSE	0,000134	0,000223	0,000487
MAE	0,0000969	0,000174	0,000375
MAPE	0,280547	0,512341	1,072139
R	0,999787	0,999447	0,997269
R <sup>2</sup>	0,999573	0,998893	0,994545

İlgili model mimarisi Şekil 4.23'te gösterilmiştir.




**Şekil 4.23.** Fon portföy dağılımı ile DBP'nin kapanış fiyatının tahmini için geliştirilen iki gizli katmanlı YSA model mimarisi (eğitim algoritması: BR, model: 49-5-10-1)

Performans ölçütlerinden MSE'nin eğitim ve test için performansı Şekil 4.24'te gösterilmektedir. Şekilden en iyi eğitim performansının 1,6723E-08 MSE ile 106. eğitim turunda elde edildiği sonucu çıkarılabilir.




**Şekil 4.24.** Fon portföy dağılımı ile DBP'nin kapanış fiyatının tahmini için geliştirilen iki gizli katmanlı YSA'nın MSE Performansı (eğitim algoritması: BR, model: 49-5-10-1)

Şekil 4.25, eğitim durumu grafiklerini göstermektedir. Gradyan grafiğinde derece değeri olarak tespit edilen  $9,2140E-08$ , hatanın neredeyse minimum olduğu anlamına gelmektedir. Mu değeri, sinir ağını eğitmek için kullanılan algoritmanın kontrol parametresidir ve mu değeri 5'tir. "Şekildeki gamk grafiğinde etkin parametre sayısı 126,465 olarak görülmektedir. Bu da iki gizli katmanlı YSA modelinin eğitim sürecinde, sinir ağı alt modelinin yaklaşık 127 parametre içerdiği anlamına gelmektedir. Şekildeki ssX grafiğinde, kareler toplamı parametresini ifade eden ssX fonksiyonunun değeri 79,5725 olarak verilmiştir. Doğrulama hatası grafiği, kontrol setindeki hata değişimini göstermektedir. Grafikteki doğrulama hatası değeri, doğrulama kontrollerindeki başarısızlıkların sayısıdır. Bu değer tüm eğitim turları için sıfırdır.




**Şekil 4.25.** Fon portföy dağılımı ile DBP'nin kapanış fiyatının tahmini için geliştirilen iki gizli katmanlı YSA'nın eğitim durumu (eğitim algoritması: BR, model: 49-5-10-1)

Eğitilmiş ağıın eğitim ve test hatalarından oluşan bir hata histogramı Şekil 4.26'da gösterilmiştir. Şekil incelendiğinde hataların çoğunun  $\pm 0,004$  aralığında olduğu ve maksimum hatanın yaklaşık olarak 0,007 olduğu tespit edilebilir. Ayrıca sıfır hata noktası  $-1,8E-05$  merkezli tanımlanmış bölmenin altına düşmektedir. Bu nedenle, elde edilen hataya bağlı olarak, eğitilmiş ağı, yatırım fonu kapanış fiyatının tahmini için gönül rahatlığıyla kullanılabilir.



**Şekil 4.26.** Fon portföy dağılımı ile DBP'nin kapanış fiyatının tahmini için geliştirilen iki gizli katmanlı YSA'nın hata histogramı (eğitim algoritması: BR, model: 49-5-10-1)

Ağın gerçekleşen ve tahmin edilen değerler arasındaki regresyon grafiği Şekil 4.27'de gösterilmiştir. Şekilde görüldüğü üzere YSA modelinin eğitim ve test için korelasyon katsayısı değerleri sırasıyla 0,99981 ve 0,99979'dur. Ayrıca tüm veriler için elde edilen korelasyon katsayısı değerinin 0,99981 olması, elde edilen tahmin modelinin çıktılarının gerçekleşen çıktı değerleriyle uyum içinde olduğu ve bu değerler arasında sapma olmadığı anlamına gelmektedir.



**Şekil 4.27.** Fon portföy dağılımı ile DBP'nin kapanış fiyatının tahmini için geliştirilen iki gizli katmanlı YSA'nın regresyon grafikleri (eğitim algoritması: BR, model: 49-5-10-1)

#### 4.1.1.2.2. En çok işlem gören yatırım fonuna ilişkin bulgular

IST'nin kapanış fiyatının, fonun portföy dağılımından tahmin edilmesi için geliştirilen tüm iki gizli katmanlı YSA model mimarilerinin eğitimi sonucunda elde edilen performans ölçütlerine ilişkin ortalama, standart sapma, en büyük ve en küçük değerler Çizelge 4.20'de gösterilmiştir.



**Çizelge 4.20.** IST'nin fon portföy dağılımının iki gizli katmanlı YSA ile eğitimi sonucu elde edilen kapanış fiyatı tahminine ilişkin performans ölçüt değerleri

Performans Ölçütleri		SSE	MSE	RMSE	MAE	MAPE	R	R <sup>2</sup>
BR	Ortalama	0,000794	8,28E-07	0,000848	0,000592	2,648501	0,985814	0,971959
	St. Sapma	0,001459	1,52E-06	0,000329	0,000292	1,220448	0,011439	0,021263
	En Büyük	0,026539	2,77E-05	0,005261	0,004759	19,88531	<b>0,996929</b>	<b>0,993868</b>
	En Küçük	<b>0,000159</b>	<b>1,66E-07</b>	<b>0,000407</b>	<b>0,000253</b>	<b>1,127645</b>	0,746828	0,557751
LM	Ortalama	0,000738	9,34E-07	0,000931	0,000660	2,947701	0,982656	0,965940
	St. Sapma	0,000670	8,48E-07	0,000259	0,000213	0,878398	0,018067	0,030610
	En Büyük	0,015506	1,96E-05	0,004430	0,003463	14,34566	0,993778	0,987595
	En Küçük	0,000263	3,33E-07	0,000577	0,000370	1,693702	0,549487	0,301936
SCG	Ortalama	0,002074	2,63E-06	0,001474	0,001147	4,945797	0,935523	0,905647
	St. Sapma	0,003404	4,31E-06	0,000674	0,000633	2,607034	0,174482	0,149264
	En Büyük	0,022279	2,82E-05	0,005310	0,004813	20,06597	0,983715	0,967696
	En Küçük	0,000703	8,89E-07	0,000943	0,000692	3,068941	-0,514180	1,67E-67

IST'nin fon portföy dağılımının iki gizli katmanlı YSA ile eğitimi sonucu elde edilen performans ölçütlerinden SSE, MSE, RMSE, R ve R<sup>2</sup> için en iyi değerlere BR eğitim algoritmasına ve 49-10-10-1 model mimarisine sahip ağda ulaşılmıştır. MAE ve MAPE performans ölçütleri içinse en iyi değerlere diğer bir BR eğitim algoritmasına ve 49-10-10-1 model mimarisine sahip ağda ulaşılmıştır.

IST'nin kapanış fiyatının, fonun portföy dağılımından tahmin edilmesi için geliştirilen tüm iki gizli katmanlı YSA model mimarilerinin doğrulanması sonucunda elde edilen performans ölçütlerine ilişkin ortalama, standart sapma, en büyük ve en küçük değerler Çizelge 4.21'de gösterilmiştir.

**Çizelge 4.21.** IST'nin fon portföy dağılımının iki gizli katmanlı YSA ile doğrulanması sonucu elde edilen kapanış fiyatı tahminine ilişkin performans ölçüt değerleri

Performans Ölçütleri		SSE	MSE	RMSE	MAE	MAPE	R	R <sup>2</sup>
BR	Ortalama	-	-	-	-	-	-	-
	St. Sapma	-	-	-	-	-	-	-
	En Büyük	-	-	-	-	-	-	-
	En Küçük	-	-	-	-	-	-	-
LM	Ortalama	0,000175	1,04E-06	0,000988	0,000703	3,122667	0,980756	0,962175
	St. Sapma	0,000132	7,83E-07	0,000248	0,000200	0,830007	0,017125	0,029551
	En Büyük	0,002858	1,69E-05	0,004112	0,003050	12,91022	<b>0,994735</b>	<b>0,989497</b>
	En Küçük	<b>0,000054</b>	<b>3,19E-07</b>	<b>0,000565</b>	<b>0,000403</b>	<b>1,779110</b>	0,581859	0,338560
SCG	Ortalama	0,000455	2,69E-06	0,001493	0,001159	4,997930	0,934129	0,903493
	St. Sapma	0,000736	4,36E-06	0,000680	0,000637	2,630247	0,175772	0,149176
	En Büyük	0,005270	3,12E-05	0,005584	0,005088	21,25186	0,987871	0,975888
	En Küçük	0,000113	6,67E-07	0,000817	0,000554	2,312938	-0,59041	5,15E-69


IST'nin fon portföy dağılımının iki gizli katmanlı YSA ile doğrulanması sonucu elde edilen performans ölçütlerinin tamamı için en iyi değerlere LM eğitim algoritmasına ve 49-8-10-1 model mimarisine sahip ağda ulaşılmıştır.

IST'nin kapanış fiyatının, fonun portföy dağılımından tahmin edilmesi için geliştirilen tüm iki gizli katmanlı YSA model mimarilerinin test edilmesi sonucunda elde edilen performans ölçütlerine ilişkin ortalama, standart sapma, en büyük ve en küçük değerler Çizelge 4.22'de gösterilmiştir. Geliştirilen tüm iki gizli katmanlı YSA mimarilerinin test edilmesi sonucunda elde edilen en iyi MSE, MAPE ve R performans ölçüt değerlerinin birinci gizli katman nöron sayısı – ikinci gizli katman nöron sayısı çiftine göre değişimi ise sırasıyla Şekil 4.28, Şekil 4.29 ve Şekil 4.30'da gösterilmiştir.


**Çizelge 4.22.** IST'nin fon portföy dağılımının iki gizli katmanlı YSA ile test edilmesi sonucu elde edilen kapanış fiyatı tahminine ilişkin performans ölçüt değerleri

Performans Ölçütleri		SSE	MSE	RMSE	MAE	MAPE	R	R <sup>2</sup>
BR	Ortalama	0,000257	1,52E-06	0,001069	0,000677	3,007735	0,977130	0,955685
	St. Sapma	0,000650	3,85E-06	0,000616	0,000269	1,103536	0,030034	0,052670
	En Büyük	0,010378	6,14E-05	0,007837	0,004677	19,47223	<b>0,994256</b>	<b>0,988545</b>
	En Küçük	<b>0,0000572</b>	<b>3,38E-07</b>	<b>0,000582</b>	<b>0,000398</b>	<b>1,699750</b>	0,639249	0,408639
LM	Ortalama	0,000191	1,13E-06	0,001028	0,000717	3,188143	0,979082	0,959005
	St. Sapma	0,000154	9,13E-07	0,000271	0,000202	0,842241	0,020094	0,033573
	En Büyük	0,003228	1,91E-05	0,004371	0,003412	14,20259	0,992876	0,985803
	En Küçük	0,0000717	4,24E-07	0,000652	0,000440	2,036508	0,502876	0,252884
SCG	Ortalama	0,000457	2,70E-06	0,001498	0,001166	5,025129	0,934174	0,903632
	St. Sapma	0,000730	4,32E-06	0,000676	0,000632	2,611480	0,175928	0,147122
	En Büyük	0,005198	3,08E-05	0,005546	0,005019	20,94212	0,985077	0,970376
	En Küçük	0,000140	8,30E-07	0,000911	0,000666	2,847668	-0,687240	2,62E-69


IST'nin fon portföy dağılımının iki gizli katmanlı YSA ile test edilmesi sonucu elde edilen performans ölçütlerinden R ve R<sup>2</sup> için en iyi değerlere BR eğitim algoritmasına ve 49-6-5-1 model mimarisine sahip ağda ulaşılmıştır. En iyi MAPE değerine BR eğitim algoritmasına ve 49-9-6-1 model mimarisine sahip ağda ulaşılmıştır. En iyi MAE değerine BR eğitim algoritmasına ve 49-10-7-1 model mimarisine sahip ağda ulaşılmıştır. Son olarak en iyi SSE, MSE ve RMSE değerlerine ise BR eğitim algoritmasına ve 49-7-7-1 model mimarisine sahip ağda ulaşılmıştır. Genel olarak performans ölçüt değerleri incelendiğinde en iyi performansın BR eğitim algoritmasına ve 49-6-5-1 model mimarisine ait ağda elde edildiği sonucuna varılabilir.



**Şekil 4.28.** Fon portföy dağılımı ile IST'nin kapanış fiyatının tahmini için geliştirilen her bir iki gizli katmanlı YSA model mimarisi için gerçekleştirilen test iterasyonları sonucunda elde edilen en iyi MSE değerleri



**Şekil 4.29.** Fon portföy dağılımı ile IST'nin kapanış fiyatının tahmini için geliştirilen her bir iki gizli katmanlı YSA model mimarisi için gerçekleştirilen test iterasyonları sonucunda elde edilen en iyi MAPE değerleri



**Şekil 4.30.** Fon portföy dağılımı ile IST'nin kapanış fiyatının tahmini için geliştirilen her bir iki gizli katmanlı YSA model mimarisine için gerçekleştirilen test iterasyonları sonucunda elde edilen en iyi R değerleri

49-6-5-1 model mimarisine sahip iki gizli katmanlı YSA'da eğitim algoritması çeşidine göre elde edilen eğitim, doğrulama ve test performans ölçüt sonuçları sırasıyla Çizelge 4.23, Çizelge 4.24 ve Çizelge 4.25'te gösterilmiştir.

**Çizelge 4.23.** IST'nin fon portföy dağılımının iki gizli katmanlı YSA ile eğitimi sonucu elde edilen kapanış fiyatı tahminine ilişkin performans ölçüt değerleri (model: 49-6-5-1)

Performans Ölçütleri	Eğitim Algoritması		
	BR	LM	SCG
SSE	0,000423	0,000342	0,001251
MSE	4,41E-07	4,33E-07	1,58E-06
RMSE	0,000664	0,000658	0,001258
MAE	0,000472	0,000441	0,000936
MAPE	2,121184	1,968713	4,149546
R	0,991787	0,992017	0,970806
R <sup>2</sup>	0,983641	0,984097	0,942464


**Çizelge 4.24.** IST'nin fon portföy dağılımının iki gizli katmanlı YSA ile doğrulanması sonucu elde edilen kapanış fiyatı tahminine ilişkin performans ölçüt değerleri (model: 49-6-5-1)

Performans Ölçütleri	Eğitim Algoritması		
	BR	LM	SCG
SSE	-	0,000109	0,000274
MSE	-	6,44E-07	1,62E-06
RMSE	-	0,000802	0,001274
MAE	-	0,000542	0,000949
MAPE	-	2,444138	4,167931
R	-	0,988063	0,969233
R <sup>2</sup>	-	0,976268	0,939412

**Çizelge 4.25.** IST'nin fon portföy dağılımının iki gizli katmanlı YSA ile test edilmesi sonucu elde edilen kapanış fiyatı tahminine ilişkin performans ölçüt değerleri (model: 49-6-5-1)


Performans Ölçütleri	Eğitim Algoritması		
	BR	LM	SCG
SSE	0,000058	0,000126	0,000224
MSE	3,43E-07	7,48E-07	1,32E-06
RMSE	0,000586	0,000865	0,001150
MAE	0,000412	0,000574	0,000867
MAPE	1,848753	2,619556	3,740660
R	0,994256	0,987021	0,975082
R <sup>2</sup>	0,988545	0,974211	0,950786

İlgili model mimarisi Şekil 4.31'de gösterilmiştir.



**Şekil 4.31.** Fon portföy dağılımı ile IST'nin kapanış fiyatının tahmini için geliştirilen iki gizli katmanlı YSA model mimarisi (eğitim algoritması: BR, model: 49-6-5-1)


Performans ölçütlerinden MSE'nin eğitim ve test için performansı Şekil 4.32'de gösterilmiştir. Şekilden en iyi eğitim performansının  $4,4145 \cdot 10^{-7}$  MSE ile 149. eğitim turunda elde edildiği sonucu çıkarılabilir.



**Şekil 4.32.** Fon portföy dağılımı ile IST'nin kapanış fiyatının tahmini için geliştirilen iki gizli katmanlı YSA'nın MSE Performansı (eğitim algoritması: BR, model: 49-6-5-1)

Şekil 4.33, eğitim durumu grafiklerini göstermektedir. Gradyan grafiğinde gradyan değeri olarak tespit edilen  $6,3375 \cdot 10^{-8}$ , hatanın neredeyse minimum olduğu anlamına gelmektedir. Mu değeri, sinir ağını eğitmek için kullanılan algoritmanın kontrol parametresidir ve mu değeri 5'tir. "Şekildeki gamk grafiğinde etkin parametre sayısı 105,4601 olarak görülmektedir. Bu da iki gizli katmanlı YSA modelinin eğitim sürecinde,

sinir ağı alt modelinin yaklaşık 106 parametre içerdiği anlamına gelmektedir. Spiegelhalter vd. (2002) etkin parametre sayısını, model karmaşıklığının bir ölçüsü olarak tanımlamışlardır. Buradan tek gizli katmanlı YSA modeli ile iki gizli katmanlı YSA alt modellerinin model karmaşıklıklarının birbirine çok yakın olduğu sonucuna varılabilir. Şekildeki ssX grafiğinde, kareler toplamı parametresini ifade eden ssX fonksiyonunun değeri 169,7184 olarak verilmiştir. Buradan iki gizli katmanlı YSA modelinin varyasyonunun tek gizli katmanlı YSA modelinin varyasyonundan çok daha yüksek olduğu sonucu çıkarılabilir. Doğrulama hatası grafiği, kontrol setindeki hata değişimini göstermektedir. Grafikteki doğrulama hatası değeri, doğrulama kontrollerindeki başarısızlıkların sayısıdır. Bu değer tüm eğitim turları için sıfırdır.




**Şekil 4.33.** Fon portföy dağılımı ile IST'nin kapanış fiyatının tahmini için geliştirilen iki gizli katmanlı YSA'nın eğitim durumu (eğitim algoritması: BR, model: 49-6-5-1)

Eğitilmiş ağı eğitim, doğrulama ve test hatalarından oluşan bir hata histogramı Şekil 4.34'te gösterilmiştir. Şekilde gösterilen hata histogramı, elde edilen veri uydurma




hatalarının normal olarak yaklaşık sıfır hata (hedef-çıktı) gibi iyi bir aralıkta dağıtıldığını göstermektedir. Şekil incelendiğinde hataların çoğunun  $\pm 0,0015$  aralığında olduğu ve maksimum hatanın yaklaşık olarak 0,003 olduğu tespit edilebilir. Ayrıca sıfır hata noktası -0,00011 merkezli tanımlanmış bölmenin altına düşmektedir. Bu nedenle, elde edilen hataya bağlı olarak, eğitilmiş ağ, yatırım fonu kapanış fiyatının tahmini için gönül rahatlığıyla kullanılabilir.



**Şekil 4.34.** Fon portföy dağılımı ile IST'nin kapanış fiyatının tahmini için geliştirilen iki gizli katmanlı YSA'nın hata histogramı (eğitim algoritması: BR, model: 49-6-5-1)

Ağın gerçekleşen değerler ile tahmin edilen değerler arasındaki regresyon grafiği Şekil 4.35'te gösterilmiştir. Şekilde görüldüğü üzere YSA modelinin eğitim ve test için korelasyon katsayısı değerleri sırasıyla 0,99179 ve 0,99426'dır. Ayrıca tüm veriler için elde edilen korelasyon katsayısı değerinin 0,99217 olması, elde edilen tahmin modelinin çıktılarının gerçekleşen çıktı değerleriyle uyum içinde olduğu ve bu değerler arasında sapma olmadığı anlamına gelmektedir.



**Şekil 4.35.** Fon portföy dağılımı ile IST'nin kapanış fiyatının tahmini için geliştirilen iki gizli katmanlı YSA'nın regresyon grafikleri (eğitim algoritması: BR, model: 49-6-5-1)

#### 4.1.2. Yatırım fonu kapanış fiyatının fon portföy dağılımından faydalanılarak tahmin edilmesi için NARX model mimarilerinin geliştirilmesi

Bu çalışmada, zaman serisi modellemede birçok avantajı nedeniyle seri paralel mimariye sahip bir NARX sinir ağı kullanılmıştır. Bu avantajlar; seri-paralel mimariye sahip NARX'in yüksek doğruluğa katkıda bulunmak için mevcut doğru çıktıyı ağa girdi olarak kullanması ve tamamen ileri beslemeli bir ağ oluşturması ve eğitim için statik geri yayılım kullanmasıdır (Umar vd., 2021). Hedeflenen (gerçekleşen) çıktının geçmiş değerleri mevcut olduğunda, NARX sinir ağının açık (seri-paralel) yapısı, daha doğru tahminler

için kullanılmaktadır (Hassan vd., 2021). Ele alınan çalışmanın nihai amacı, sistem çıktısına ( $y_t$ ) yaklaşan bir  $\hat{y}_t$  çıktısı üreten uygun bir model geliştirmektir.

NARX modellerinin belirlenmesi, sinir ağı tabanlı modellerin belirlenmesi gibi üç adımdan oluşmaktadır. İlk adım, tanımlama için uygun verileri sağlamak, ikinci adım model yapısını oluşturmak, parametreleri eğitmek ve modeli test etmek, üçüncü adım ise en uygun model yapısını bulmaktır. NARX modellerinde optimal yapı, modelin doğrusal olmayan kısmının en iyi yapısının ve en iyi  $d_x$  ve  $d_y$  değerlerinin olduğu durumdur. Böylece doğrulama aşamasında model çıktıları ile gerçek veriler arasında minimum hata hedefine erişilebilir (Amirkhani vd., 2021).

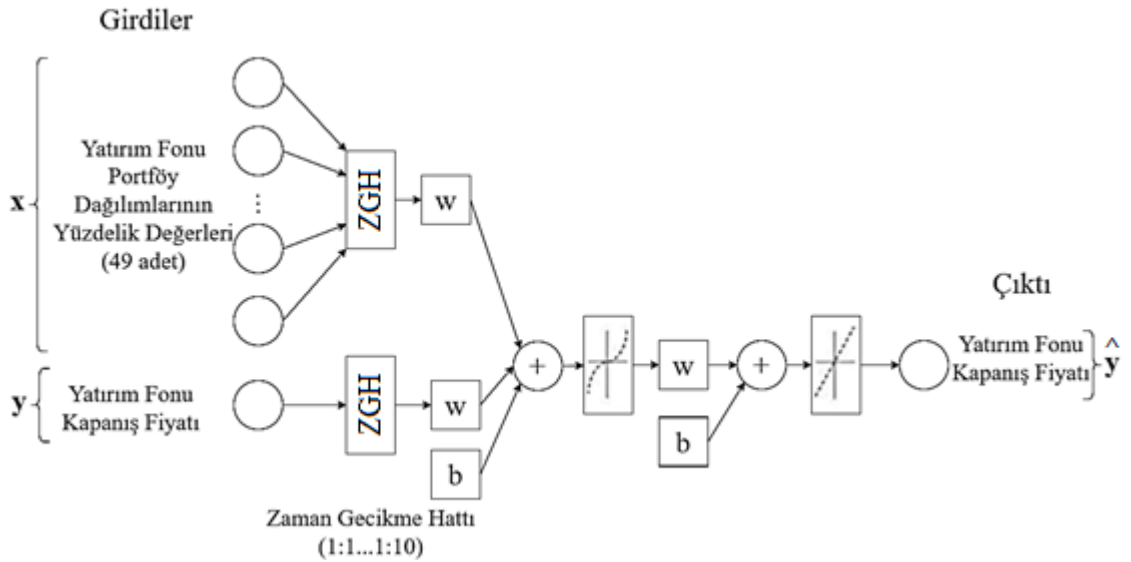
**Çizelge 4.26.** NARX algoritmasının tasarım parametreleri

Ağ parametreleri		Eğitim algoritmaları		
		LM	BR	SCG
Girdi sayısı		49	49	49
Çıktı sayısı		1	1	1
Aktivasyon fonksiyonu	Girdi-Gizli	Hiperbolik tanjant sigmoid	Hiperbolik tanjant sigmoid	Hiperbolik tanjant sigmoid
	Gizli-Çıktı	Lineer	Lineer	Lineer
Veri bölme	Eğitim	%70	%85	%70
	Doğrulama	%15	-	%15
	Test	%15	%15	%15
Eğitim tur sayısı		1000	1000	1000
Performans hedefi		0	0	0
Başlangıç mu değeri		0,005	0,001	-
mu için indirgeme faktörü		0,1	0,1	-
mu için çoğaltma faktörü		10	10	-
mu için maksimum değer		1e10	1e10	-
Maksimum doğrulama hatası		0	6	6
Minimum performans gradyanı		1e-7	1e-7	1e-6
Sigma		-	-	5e-5
Lambda		-	-	5e-7

Çalışmada NARX ağlarını eğitmek için LM, BR ve SCG eğitim algoritmalarından faydalanılmıştır.

Dinamik sinir ağı doğrusal olmayan bir zaman serisi probleminin çözümünde kullanılan ağ modelinin yapısı girdi sayısı, çıktı sayısı, girdi katmanı – gizli katman – çıktı katmanı arasındaki aktivasyon fonksiyonları, verinin eğitim – doğrulama – test dağılımı oranı, döngü sayısı ve hata hedefi gibi parametreleri içermektedir. Önerilen ağ modelinin tasarımında kullanılan parametreler, analizde faydalanılan eğitim algoritmalarına göre Çizelge 4.26’da gösterildiği gibi sınıflandırılmıştır. İlgili menkul kıymet yatırım fonlarının günlük kapanış fiyatı tahminini yapmak amacıyla girdi olarak fonların 49 kalemden oluşan portföy dağılımlarının yüzdeler değeri kullanılmıştır. Çıktı ise fonun günlük kapanış fiyatıdır.

Çalışmada inceleme altına alınacak yatırım fonlarının kapanış fiyatının fon portföy dağılımından faydalanılarak tahmin edilmesi için geliştirilen NARX sinir ağı mimarisi Şekil 4.36’da gösterilmiştir. NARX model mimarisine örnek olarak 49-(2)-3-1 gösterimi verilebilir. Gösterimde 49 sayısı girdi sayısını, (2) sayısı gecikme sayısını, 3 sayısı gizli katman nöron sayısını ve 1 sayısı çıktı sayısını temsil etmektedir.



Şekil 4.36. Yatırım fonu kapanış fiyatının fon portföy dağılımından faydalanılarak tahmin edilmesi için geliştirilen NARX sinir ağı model mimarisi

NARX modelinin çözümünde üç farklı eğitim algoritması kullanılarak, gizli katman nöron sayısı 1 ile 10 arasında değişecek şekilde ve gecikme sayısı 1 ile 10 arasında değişecek şekilde her bir fon için toplam 300 farklı ağ yapısı üzerine çalışılmıştır. Bu 300 farklı ağ yapısı için analiz onar defa tekrarlanmış ve her bir fon için 3000 olmak üzere toplam 6000 analiz gerçekleştirilmiştir.

NARX modelini eğittikten sonra, modelin tahmininin doğruluğunu değerlendirmek için SSE, MSE, RMSE, MAE, MAPE, R ve R<sup>2</sup> performans ölçütlerinden faydalanılmıştır.

#### 4.1.2.1. En fazla sayıda portföye dağılan yatırım fonuna ilişkin bulgular

DBP'nin kapanış fiyatının, fonun portföy dağılımından tahmin edilmesi için geliştirilen tüm NARX model mimarilerinin eğitimi sonucunda elde edilen performans ölçütlerine ilişkin ortalama, standart sapma, en büyük ve en küçük değerler Çizelge 4.27'de gösterilmiştir.

**Çizelge 4.27.** DBP'nin fon portföy dağılımının NARX ile eğitimi sonucu elde edilen kapanış fiyatı tahminine ilişkin performans ölçüt değerleri

Performans Ölçütleri		SSE	MSE	RMSE	MAE	MAPE	R	R <sup>2</sup>
BR	Ortalama	1,29E-04	1,35E-07	7,94E-05	5,67E-05	0,162326	0,996625	0,997074
	St. Sapma	2,29E-03	2,40E-06	3,59E-04	3,22E-04	0,956970	0,061736	0,051906
	En Büyük	4,24E-02	4,44E-05	6,66E-03	5,98E-03	17,75280	0,999986	0,999972
	En Küçük	1,16E-06	1,22E-09	3,50E-05	2,38E-05	0,069050	-0,344660	0,017061
LM	Ortalama	9,14E-06	1,16E-08	7,87E-05	5,57E-05	0,160637	0,999893	0,999786
	St. Sapma	5,97E-05	7,59E-08	7,37E-05	5,13E-05	0,150728	0,000781	0,001544
	En Büyük	1,64E-03	2,08E-06	1,44E-03	8,44E-04	2,570710	<b>0,999992</b>	<b>0,999983</b>
	En Küçük	<b>5,89E-07</b>	<b>7,53E-10</b>	<b>2,74E-05</b>	<b>1,90E-05</b>	<b>0,054633</b>	0,975940	0,952459
SCG	Ortalama	8,59E-04	1,10E-06	5,83E-04	4,55E-04	1,328194	0,978935	0,978000
	St. Sapma	4,70E-03	5,99E-06	8,69E-04	7,81E-04	2,313938	0,140306	0,118731
	En Büyük	3,57E-02	4,55E-05	6,75E-03	6,06E-03	17,98860	0,999360	0,998720
	En Küçük	4,33E-05	5,53E-08	2,35E-04	1,83E-04	0,532629	-0,64783	0,000773

DBP'nin fon portföy dağılımının NARX ile eğitimi sonucu elde edilen performans ölçütlerinden R ve R<sup>2</sup> için en iyi değerlere LM eğitim algoritmasına ve 49-(8)-10-1 model mimarisine sahip ağda ulaşılmıştır. En iyi SSE, MSE ve RMSE değerlerine LM eğitim

algoritmasına ve 49-(10)-10-1 model mimarisine sahip ağda ulaşılmıştır. Son olarak en iyi MAE ve MAPE değerlerine LM eğitim algoritmasına ve 49-(10)-8-1 model mimarisine sahip ağda ulaşılmıştır.

DBP'nin kapanış fiyatının, fonun portföy dağılımından tahmin edilmesi için geliştirilen tüm NARX model mimarilerinin doğrulanması sonucunda elde edilen performans ölçütlerine ilişkin ortalama, standart sapma, en büyük ve en küçük değerler Çizelge 4.28'de gösterilmiştir.

**Çizelge 4.28.** DBP'nin fon portföy dağılımının NARX ile doğrulanması sonucu elde edilen kapanış fiyatı tahminine ilişkin performans ölçüt değerleri

Performans Ölçütleri		SSE	MSE	RMSE	MAE	MAPE	R	R <sup>2</sup>
BR	Ortalama	-	-	-	-	-	-	-
	St. Sapma	-	-	-	-	-	-	-
	En Büyük	-	-	-	-	-	-	-
	En Küçük	-	-	-	-	-	-	-
LM	Ortalama	7,66E-06	4,55E-08	0,000170	8,99E-05	0,251659	0,999513	0,999028
	St. Sapma	2,14E-05	1,27E-07	0,000129	5,76E-05	0,162185	0,001295	0,002571
	En Büyük	3,89E-04	2,30E-06	0,001516	8,46E-04	2,480605	<b>0,999980</b>	<b>0,999960</b>
	En Küçük	<b>2,70E-07</b>	<b>1,60E-09</b>	<b>0,000040</b>	<b>2,88E-05</b>	<b>0,081575</b>	0,976083	0,952738
SCG	Ortalama	1,94E-04	1,15E-06	0,000643	4,76E-04	1,387518	0,978376	0,976604
	St. Sapma	9,95E-04	5,91E-06	0,000860	7,71E-04	2,296187	0,139229	0,117525
	En Büyük	7,93E-03	4,72E-05	0,006869	6,15E-03	18,78865	0,999317	0,998634
	En Küçük	1,06E-05	6,28E-08	0,000251	1,90E-04	0,545000	-0,663540	0,000360

DBP'nin fon portföy dağılımının NARX ile doğrulanması sonucu elde edilen performans ölçütlerinden tamamı için en iyi değerlere LM eğitim algoritmasına ve 49-(1)-10-1 model mimarisine sahip ağda ulaşılmıştır.


DBP'nin kapanış fiyatının, fonun portföy dağılımından tahmin edilmesi için geliştirilen tüm NARX model mimarilerinin test edilmesi sonucunda elde edilen performans ölçütlerine ilişkin ortalama, standart sapma, en büyük ve en küçük değerler Çizelge 4.29'da gösterilmiştir. Geliştirilen tüm NARX mimarilerinin test edilmesi sonucunda elde edilen en iyi MSE, MAPE ve R performans ölçüt değerlerinin gecikme sayısı - gizli

katman nöron sayısı çiftine göre değişimi ise sırasıyla Şekil 4.37, Şekil 4.38 ve Şekil 4.39'da gösterilmiştir.


**Çizelge 4.29.** DBP'nin fon portföy dağılımının NARX ile test edilmesi sonucu elde edilen kapanış fiyatı tahminine ilişkin performans ölçüt değerleri

Performans Ölçütleri		SSE	MSE	RMSE	MAE	MAPE	R	R <sup>2</sup>
BR	Ortalama	2,44E-05	1,45E-07	1,11E-04	7,10E-05	0,20164	0,996534	0,996944
	St. Sapma	4,17E-04	2,47E-06	3,64E-04	3,26E-04	0,987532	0,062156	0,051960
	En Büyük	8,09E-03	4,82E-05	6,94E-03	6,28E-03	18,55013	<b>0,999981</b>	<b>0,999961</b>
	En Küçük	<b>3,11E-07</b>	<b>1,84E-09</b>	<b>4,29E-05</b>	<b>2,99E-05</b>	<b>0,082591</b>	-0,316460	0,018307
LM	Ortalama	1,16E-05	6,88E-08	1,94E-04	9,20E-05	0,257152	0,999240	0,998490
	St. Sapma	4,37E-05	2,59E-07	1,77E-04	5,34E-05	0,153733	0,002982	0,005853
	En Büyük	8,13E-04	4,81E-06	2,19E-03	8,64E-04	2,594401	0,999973	0,999945
	En Küçük	4,33E-07	2,56E-09	5,06E-05	3,43E-05	0,096283	0,944408	0,891907
SCG	Ortalama	1,97E-04	1,17E-06	6,53E-04	4,84E-04	1,410513	0,977757	0,976386
	St. Sapma	1,01E-03	5,97E-06	8,63E-04	7,75E-04	2,309230	0,142749	0,117992
	En Büyük	8,54E-03	5,08E-05	7,13E-03	6,39E-03	18,77611	0,999170	0,998341
	En Küçük	1,30E-05	7,68E-08	2,77E-04	1,96E-04	0,578317	-0,641150	0,000625

DBP'nin fon portföy dağılımının NARX ile test edilmesi sonucu elde edilen performans ölçütlerinin tamamı için en iyi değerlere BR eğitim algoritmasına ve 49-(1)-5-1 model mimarisine sahip ağda ulaşılmıştır.




**Şekil 4.37.** Fon portföy dağılımı ile DBP'nin kapanış fiyatının tahmini için geliştirilen her bir NARX model mimarisi için gerçekleştirilen test iterasyonları sonucunda elde edilen en iyi MSE değerleri



**Şekil 4.38.** Fon portföy dağılımı ile DBP'nin kapanış fiyatının tahmini için geliştirilen her bir NARX model mimarisi için gerçekleştirilen test iterasyonları sonucunda elde edilen en iyi MAPE değerleri





**Şekil 4.39.** Fon portföy dağılımı ile DBP'nin kapanış fiyatının tahmini için geliştirilen her bir NARX model mimarisine için gerçekleştirilen test iterasyonları sonucunda elde edilen en iyi R değerleri

49-(1)-5-1 model mimarisine sahip NARX ağında eğitim algoritması çeşidine göre elde edilen eğitim, doğrulama ve test performans ölçüt sonuçları sırasıyla Çizelge 4.30, Çizelge 4.31 ve Çizelge 4.32'de gösterilmiştir.

**Çizelge 4.30.** DBP'nin fon portföy dağılımının NARX ile eğitimi sonucu elde edilen kapanış fiyatı tahminine ilişkin performans ölçüt değerleri (model: 49-(1)-5-1)

Performans Ölçütleri	Eğitim Algoritması		
	BR	LM	SCG
SSE	3,34E-06	2,61E-06	9,91E-05
MSE	3,48E-09	3,30E-09	1,26E-07
RMSE	5,90E-05	5,75E-05	3,54E-04
MAE	3,62E-05	3,56E-05	2,61E-04
MAPE	0,100481	0,098027	0,773764
R	0,999960	0,999964	0,998575
R <sup>2</sup>	0,999920	0,999927	0,997151

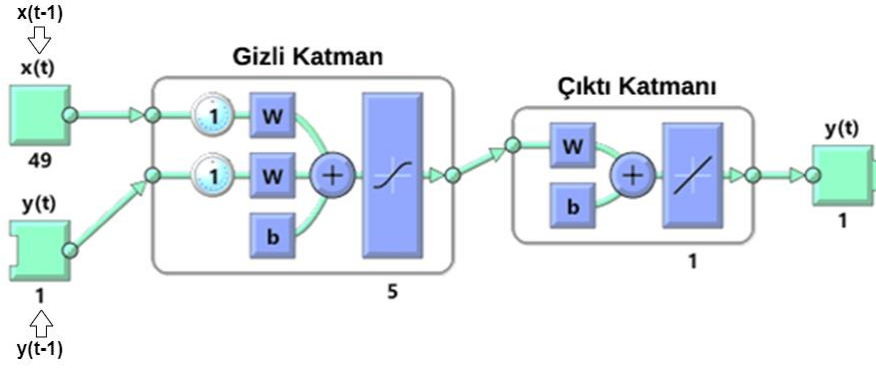
**Çizelge 4.31.** DBP'nin fon portföy dağılımının NARX ile doğrulanması sonucu elde edilen kapanış fiyatı tahminine ilişkin performans ölçüt değerleri (model: 49-(1)-5-1)

Performans Ölçütleri	Eğitim Algoritması		
	BR	LM	SCG
SSE	-	5,34E-07	2,36E-05
MSE	-	3,16E-09	1,40E-07
RMSE	-	5,62E-05	3,74E-04
MAE	-	3,45E-05	2,64E-04
MAPE	-	0,097942	0,732611
R	-	0,999958	0,998604
R <sup>2</sup>	-	0,999916	0,997210

**Çizelge 4.32.** DBP'nin fon portföy dağılımının NARX ile test edilmesi sonucu elde edilen kapanış fiyatı tahminine ilişkin performans ölçüt değerleri (model: 49-(1)-5-1)


Performans Ölçütleri	Eğitim Algoritması		
	BR	LM	SCG
SSE	3,11E-07	4,33E-07	1,88E-05
MSE	1,84E-09	2,56E-09	1,11E-07
RMSE	4,29E-05	5,06E-05	3,34E-04
MAE	2,99E-05	3,43E-05	2,47E-04
MAPE	0,082591	0,096283	0,727195
R	0,999981	0,999973	0,998748
R <sup>2</sup>	0,999961	0,999945	0,997497

Bahsi geçen model mimarisi Şekil 4.40'ta gösterilmiştir.



**Şekil 4.40.** Fon portföy dağılımı ile DBP'nin kapanış fiyatının tahmini için geliştirilen NARX model mimarisi (eğitim algoritması: BR, model: 49-(1)-5-1)


Performans ölçütlerinden MSE'nin eğitim ve test performansı Şekil 4.41'de gösterilmiştir. Şekilden en iyi eğitim performansının 3,485E-09 MSE ile 11. eğitim turunda elde edildiği sonucu çıkarılabilir.



**Şekil 4.41.** Fon portföy dağılımı ile DBP'nin kapanış fiyatının tahmini için geliştirilen NARX'in MSE Performansı (eğitim algoritması: BR, model: 49-(1)-5-1)


Şekil 4.42, eğitim durumu grafiklerini göstermektedir. Şekildeki gradyan grafiğinde gradyan değeri olarak tespit edilen 5,6112E-08, hatanın neredeyse minimum olduğu

anlamına gelmektedir. Şekildeki mu grafiğinde mu değeri 50 olarak gösterilmiştir. Şekildeki gamk grafiğinde etkin parametre sayısı 64,4789 olarak elde edilmiştir. Bu da NARX modelinin eğitim sürecinde, sinir ağı alt modelinin yaklaşık 65 parametre içerdiği anlamına gelmektedir. Spiegelhalter vd. (2002) etkin parametre sayısını, model karmaşıklığının bir ölçüsü olarak tanımlamışlardır. Buradan tek gizli katmanlı YSA modeli ile iki gizli katmanlı YSA alt modellerinin model karmaşıklığının NARX alt modelinkinden çok daha yüksek olduğu sonucu çıkarılabilir. Bu da büyük veri modelleme problemleri için YSA alt modellerinin NARX alt modeline kıyasla daha uzun sürede eğitilebileceği anlamına gelmektedir. Şekildeki ssX grafiğinde, ssX parametresinin değeri 2,8772 olarak verilmiştir. Buradan tek gizli katmanlı YSA modeli ile iki gizli katmanlı YSA modellerinin varyasyonunun NARX modelinin varyasyonundan çok daha yüksek olduğu sonucu çıkarılabilir. Son olarak şekildeki doğrulama hatası grafiğinde doğrulama kontrollerindeki başarısızlık sayısını temsil eden doğrulama değeri tüm eğitim turları için sıfır olarak görülmektedir.




**Şekil 4.42.** Fon portföy dağılımı ile DBP'nin kapanış fiyatının tahmini için geliştirilen NARX'in eğitim durumu (eğitim algoritması: BR, model: 49-(1)-5-1)

Eđitilmiş ađın eđitim ve test hatalarından oluřan bir hata histogramı Őekil 4.43'te gsterilmiřtir. Őekil incelendiđinde hataların ođunun  $\pm 0,0002$  aralıđında olduđu ve maksimum hatanın yaklařık olarak 0,0005 olduđu tespit edilebilir. Ayrıca sıfır hata noktası  $-7,12E-06$  merkezli tanımlanmıř blmenin altına dřmektedir. Bu nedenle, elde edilen hataya bađlı olarak, eđitimi ađ, yatırım fonu kapanıř fiyatının tahmini iin gnl rahatlıđıyla kullanılabilir.




**Őekil 4.43.** Fon portfy dađılımı ile DBP'nin kapanıř fiyatının tahmini iin geliřtirilen NARX'in hata histogramı (eđitim algoritması: BR, model: 49-(1)-5-1)

Ađın gerekleřen deđerler ile tahmin edilen deđerler arasındaki regresyon grafiđi Őekil 4.44'te gsterilmiřtir. Őekilde grldđ zere NARX modelinin eđitim ve test iin korelasyon katsayısı deđerleri sırasıyla 0,99996 ve 0,99998'dir. Ayrıca tm veriler iin elde edilen korelasyon katsayısı deđerinin 0,99996 olması, elde edilen tahmin modelinin ıktılarının gerekleřen ıktı deđerleriyle uyum iinde olduđu ve bu deđerler arasında sapma olmadıđı anlamına gelmektedir.




**Şekil 4.44.** Fon portföy dağılımı ile DBP'nin kapanış fiyatının tahmini için geliştirilen NARX'in regresyon grafikleri (eğitim algoritması: BR, model: 49-(1)-5-1)

Şekil 4.45, eğitilmiş çıktı değeri ile hedeflenen (gerçekleşen) değerlerin karşılaştırmasını gösterir. Bu değerler arasındaki farkın (hatanın) az olması sonucun daha iyi olması anlamına gelmektedir (Aji vd., 2019).




**Şekil 4.45.** Fon portföy dağılımı ile DBP'nin kapanış fiyatının tahmini için geliştirilen NARX'in tahmin sonuçları (eğitim algoritması: BR, model: 49-(1)-5-1)

Uygulama performansını doğrulamak amacıyla tahmin prosedürü ile elde edilen otokorelasyonlar Şekil 4.46'da gösterilmiştir. Hata otokorelasyonu şekli, tahmin hatalarının zaman içerisinde nasıl ilişkilendirildiğini açıklamaktadır (Louzazni vd., 2020). Şekilde sıfır korelasyonu hariç hata korelasyonlarının neredeyse tamamı %95 güven aralığında yer almakta ve sıfır değeri etrafında dalgalanma göstermektedir. Bu durum, bu modelin makul, amaca yönelik ve güvenilir olduğu çıkarımı yapılmasına olanak sağlar.



**Şekil 4.46.** Fon portföy dağılımı ile DBP'nin kapanış fiyatının tahmini için geliştirilen NARX'in hata otokorelasyonları (eğitim algoritması: BR, model: 49-(1)-5-1)

Şekil 4.47'de gösterilen girdi-hata çapraz korelasyon fonksiyonu, hataların girdi dizisi ile nasıl ilişkilendirildiğini göstermektedir. Mükemmel bir tahmin modeli için tüm korelasyonlar sıfır olmalıdır. Çapraz korelasyon tarafından sağlanan girdi hatası, tüm korelasyonlar sıfır olduğunda hataların girdi örüntüsü ile nasıl ilişkilendirildiğini açıklar ve bu sayede mükemmel bir tahmin modeli elde edilir (Fırat, 2020; Louzazni vd., 2020; Matzenberger, 2013). Şekil, girdi çıktı hatası çapraz korelasyonunun %95 güven sınırı içinde olduğunu göstermektedir ve tüm korelasyonlar neredeyse sıfıra yakındır. Bu da yeterli bir tahmin modelinin olduğunu göstermektedir.



**Şekil 4.47.** Fon portföy dağılımı ile DBP'nin kapanış fiyatının tahmini için geliştirilen NARX'in girdi-hata çapraz-korelasyonları (eğitim algoritması: BR, model: 49-(1)-5-1)



#### 4.1.2.2. En çok işlem gören yatırım fonuna ilişkin bulgular

IST'nin kapanış fiyatının, fonun portföy dağılımından tahmin edilmesi için geliştirilen tüm NARX model mimarilerinin eğitimi sonucunda elde edilen performans ölçütlerine ilişkin ortalama, standart sapma, en büyük ve en küçük değerler Çizelge 4.33'te gösterilmiştir.

**Çizelge 4.33.** IST'nin fon portföy dağılımının NARX ile eğitimi sonucu elde edilen kapanış fiyatı tahminine ilişkin performans ölçüt değerleri

Performans Ölçütleri	SSE	MSE	RMSE	MAE	MAPE	R	R <sup>2</sup>	
BR	Ortalama	1,81E-04	1,90E-07	5,47E-05	4,61E-05	0,189564	0,993070	0,993738
	St. Sapma	2,15E-03	2,25E-06	4,32E-04	3,89E-04	1,621019	0,086889	0,075245
	En Büyük	2,62E-02	2,74E-05	5,24E-03	4,71E-03	19,67369	0,999999	0,999998
	En Küçük	5,48E-08	5,76E-11	7,59E-06	5,12E-06	0,020919	-0,605390	0,006426
LM	Ortalama	6,72E-05	8,56E-08	6,22E-05	4,88E-05	0,198597	0,996884	0,996873
	St. Sapma	1,15E-03	1,47E-06	2,86E-04	2,56E-04	1,069132	0,055635	0,053957
	En Büyük	2,13E-02	2,70E-05	5,20E-03	4,68E-03	19,55012	<b>1,000000</b>	<b>0,999999</b>
	En Küçük	<b>1,21E-08</b>	<b>1,55E-11</b>	<b>3,93E-06</b>	<b>2,44E-06</b>	<b>0,009966</b>	-0,157300	1,61E-06
SCG	Ortalama	6,68E-04	8,51E-07	5,60E-04	4,38E-04	1,806688	0,970828	0,971011
	St. Sapma	3,19E-03	4,06E-06	7,33E-04	6,66E-04	2,786142	0,168832	0,135448
	En Büyük	2,21E-02	2,82E-05	5,31E-03	4,80E-03	20,36193	0,999093	0,998187
	En Küçük	3,76E-05	4,80E-08	2,19E-04	1,64E-04	0,663787	-0,633110	4,46E-07

IST'nin NARX ile eğitilmesi sonucu elde edilen performans ölçütlerinden MAE ve MAPE hariç tamamı için en iyi değerlere LM eğitim algoritmasına ve 49-(10)-8-1 model mimarisine sahip ağda ulaşılmıştır. En iyi MAE ve MAPE değerlerine ise LM eğitim algoritmasına ve 48-(8)-10-1 model mimarisine sahip ağda ulaşılmıştır.

IST'nin kapanış fiyatının, fonun portföy dağılımından tahmin edilmesi için geliştirilen tüm NARX model mimarilerinin doğrulanması sonucunda elde edilen performans ölçütlerine ilişkin ortalama, standart sapma, en büyük ve en küçük değerler Çizelge 4.34'te gösterilmiştir.

**Çizelge 4.34.** IST'nin fon portföy dağılımının NARX ile doğrulanması sonucu elde edilen kapanış fiyatı tahminine ilişkin performans ölçüt değerleri

Performans Ölçütleri		SSE	MSE	RMSE	MAE	MAPE	R	R <sup>2</sup>
BR	Ortalama	-	-	-	-	-	-	-
	St. Sapma	-	-	-	-	-	-	-
	En Büyük	-	-	-	-	-	-	-
	En Küçük	-	-	-	-	-	-	-
LM	Ortalama	1,59E-05	9,41E-08	9,59E-05	6,05E-05	0,242937	0,996493	0,996633
	St. Sapma	2,50E-04	1,48E-06	2,91E-04	2,56E-04	1,094464	0,060292	0,053464
	En Büyük	4,65E-03	2,75E-05	5,25E-03	4,71E-03	20,17333	<b>0,999998</b>	<b>0,999997</b>
	En Küçük	<b>1,69E-08</b>	<b>1,00E-10</b>	<b>1,00E-05</b>	<b>7,43E-06</b>	<b>0,029516</b>	-0,227140	0,002766
SCG	Ortalama	1,47E-04	8,76E-07	5,91E-04	4,55E-04	1,872287	0,970723	0,970444
	St. Sapma	6,81E-04	4,04E-06	7,26E-04	6,63E-04	2,761595	0,167749	0,132866
	En Büyük	5,31E-03	3,14E-05	5,60E-03	5,16E-03	21,93368	0,998966	0,997934
	En Küçük	9,33E-06	5,52E-08	2,35E-04	1,68E-04	0,669356	-0,581350	1,62E-69


IST'nin NARX ile doğrulanması sonucu elde edilen performans ölçütlerinden MAE ve MAPE hariç tamamı için en iyi değerlere LM eğitim algoritmasına ve 49-(1)-10-1 model mimarisine sahip ağda ulaşılmıştır. En iyi MAE ve MAPE değerlerine ise LM eğitim algoritmasına ve 48-(3)-9-1 model mimarisine sahip ağda ulaşılmıştır.

IST'nin kapanış fiyatının, fonun portföy dağılımından tahmin edilmesi için geliştirilen tüm NARX model mimarilerinin test edilmesi sonucunda elde edilen performans ölçütlerine ilişkin ortalama, standart sapma, en büyük ve en küçük değerler Çizelge 4.35'te gösterilmiştir. Geliştirilen tüm NARX mimarilerinin test edilmesi sonucunda elde edilen en iyi MSE, MAPE ve R performans ölçüt değerlerinin gecikme sayısı - gizli katman nöron sayısı çiftine göre değişimi ise sırasıyla Şekil 4.48, Şekil 4.49 ve Şekil 4.50'de gösterilmiştir.


**Çizelge 4.35.** IST'nin fon portföy dağılımının NARX ile test edilmesi sonucu elde edilen kapanış fiyatı tahminine ilişkin performans ölçüt değerleri

Performans Ölçütleri		SSE	MSE	RMSE	MAE	MAPE	R	R <sup>2</sup>
BR	Ortalama	3,27E-05	1,94E-07	6,04E-05	4,88E-05	0,200970	0,993159	0,993859
	St. Sapma	3,86E-04	2,30E-06	4,37E-04	3,95E-04	1,664266	0,086564	0,073600
	En Büyük	4,91E-03	2,92E-05	5,41E-03	4,87E-03	20,53589	0,999998	0,999997
	En Küçük	1,51E-08	8,93E-11	9,45E-06	6,96E-06	0,028127	-0,617350	0,009689
LM	Ortalama	2,04E-05	1,21E-07	1,20E-04	6,30E-05	0,248698	0,996451	0,995876
	St. Sapma	2,70E-04	1,60E-06	3,26E-04	2,68E-04	1,098005	0,054430	0,053885
	En Büyük	5,33E-03	3,16E-05	5,62E-03	5,09E-03	20,91470	<b>0,999998</b>	<b>0,999997</b>
	En Küçük	<b>1,47E-08</b>	<b>8,68E-11</b>	<b>9,32E-06</b>	<b>6,84E-06</b>	<b>0,027572</b>	-0,169880	0,001789
SCG	Ortalama	1,49E-04	8,85E-07	5,97E-04	4,58E-04	1,888416	0,970638	0,970265
	St. Sapma	6,82E-04	4,05E-06	7,27E-04	6,62E-04	2,782334	0,167707	0,132161
	En Büyük	5,28E-03	3,15E-05	5,61E-03	5,17E-03	22,31202	0,998861	0,997724
	En Küçük	1,14E-05	6,72E-08	2,59E-04	1,89E-04	0,736104	-0,639010	1,57E-70


IST'nin NARX ile test edilmesi sonucu elde edilen performans ölçütlerinden en iyi R ve R<sup>2</sup> değerlerine LM eğitim algoritmasına ve 49-(2)-10-1 model mimarisine sahip ağda ulaşılmıştır. En iyi SSE, MSE ve RMSE değerlerine LM eğitim algoritmasına ve 49-1-(4)-1 model mimarisine sahip ağda ulaşılmıştır. Son olarak en iyi MAE ve MAPE değerlerine LM eğitim algoritmasına ve 49-(2)-4-1 model mimarisine sahip ağda ulaşılmıştır. Bilindiği üzere yüksek bir R değeri ve küçük bir MSE değeri, mükemmel eğitimi gösterir ve tahmin değerleri deneysel değerlere yakın olabilir. Bundan dolayı LM eğitim algoritmasına ve 49-(2)-10-1 model mimarisine ait ağın ideal sonuca ulaştıracağı sonucuna varılabilir.



**Şekil 4.48.** Fon portföy dağılımı ile IST'nin kapanış fiyatının tahmini için geliştirilen her bir NARX model mimarisi için gerçekleştirilen test iterasyonları sonucunda elde edilen en iyi MSE değerleri



**Şekil 4.49.** Fon portföy dağılımı ile IST'nin kapanış fiyatının tahmini için geliştirilen her bir NARX model mimarisi için gerçekleştirilen test iterasyonları sonucunda elde edilen en iyi MAPE değerleri



**Şekil 4.50.** Fon portföy dağılımı ile IST'nin kapanış fiyatının tahmini için geliştirilen her bir NARX model mimarisi için gerçekleştirilen test iterasyonları sonucunda elde edilen en iyi R değerleri

49-(2)-10-1 model mimarisine sahip NARX ağında eğitim algoritması çeşidine göre elde edilen eğitim, doğrulama ve test performans ölçüt sonuçları sırasıyla Çizelge 4.36, Çizelge 4.37 ve Çizelge 4.38'de gösterilmiştir.

**Çizelge 4.36.** IST'nin fon portföy dağılımının NARX ile eğitimi sonucu elde edilen kapanış fiyatı tahminine ilişkin performans ölçüt değerleri (model: 49-(2)-10-1)

Performans Ölçütleri	Eğitim Algoritması		
	BR	LM	SCG
SSE	1,26E-07	6,42E-08	8,40E-05
MSE	1,32E-10	8,15E-11	1,07E-07
RMSE	1,15E-05	9,03E-06	3,26E-04
MAE	8,67E-06	6,79E-06	2,31E-04
MAPE	0,034530	0,027204	0,936806
R	0,999998	0,999999	0,998012
R <sup>2</sup>	0,999995	0,999997	0,996029


**Çizelge 4.37.** IST'nin fon portföy dağılımının NARX ile doğrulanması sonucu elde edilen kapanış fiyatı tahminine ilişkin performans ölçüt değerleri (model: 49-(2)-10-1)

Performans Ölçütleri	Eğitim Algoritması		
	BR	LM	SCG
SSE	-	3,26E-08	4,05E-05
MSE	-	1,93E-10	2,40E-07
RMSE	-	1,39E-05	4,90E-04
MAE	-	9,12E-06	3,03E-04
MAPE	-	0,036666	1,164537
R	-	0,999996	0,995711
R <sup>2</sup>	-	0,999992	0,991440

**Çizelge 4.38.** IST'nin fon portföy dağılımının NARX ile test edilmesi sonucu elde edilen kapanış fiyatı tahminine ilişkin performans ölçüt değerleri (model: 49-(2)-10-1)


Performans Ölçütleri	Eğitim Algoritması		
	BR	LM	SCG
SSE	1,66E-08	1,49E-08	1,68E-05
MSE	9,81E-11	8,83E-11	9,97E-08
RMSE	9,90E-06	9,40E-06	3,16E-04
MAE	8,09E-06	7,25E-06	2,32E-04
MAPE	0,032022	0,029575	0,946922
R	0,999998	0,999998	0,998249
R <sup>2</sup>	0,999997	0,999997	0,996501

Bahsi geçen model mimarisi Şekil 4.51'de gösterilmiştir.



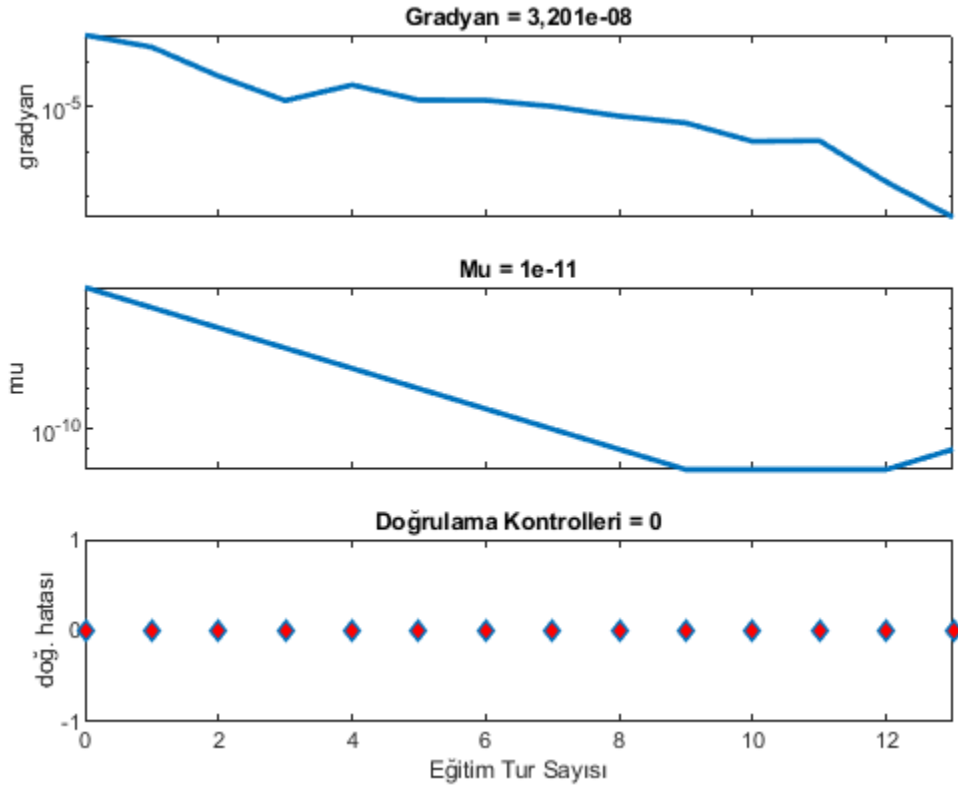
**Şekil 4.51.** Fon portföy dağılımı ile IST'nin kapanış fiyatının tahmini için geliştirilen NARX model mimarisi (eğitim algoritması: LM, model: 49-(2)-10-1)

Performans ölçütlerinden MSE'nin eğitim, doğrulama ve test performansı Şekil 4.52'de gösterilmiştir. Şekilden en iyi doğrulama performansının  $1,9263E-10$  MSE ile 13. eğitim turunda elde edildiği sonucu çıkarılabilir.



**Şekil 4.52.** Fon portföy dağılımı ile IST'nin kapanış fiyatının tahmini için geliştirilen NARX'in MSE Performansı (eğitim algoritması: LM, model: 49-(2)-10-1)

Şekil 4.53, eğitim durumu grafiklerini göstermektedir. Şekildeki gradyan grafiğinde gradyan değeri olarak tespit edilen  $3,201E-08$ , hatanın neredeyse minimum olduğu anlamına gelmektedir. Şekildeki mu grafiğinde, mu değeri  $1E-11$  olarak görülmektedir. Çok fazla başarısızlık, aşırı eğitim anlamına gelmektedir. MATLAB, arka arkaya 6 başarısızlıktan sonra eğitimi otomatik olarak durdurmaktadır (Hassan vd., 2019). Şekildeki doğrulama hatası grafiğinde doğrulama kontrollerindeki başarısızlık sayısını temsil eden doğrulama hatası değeri tüm eğitim turları için sıfır olarak görülmektedir.




**Şekil 4.53.** Fon portföy dağılımı ile IST'nin kapanış fiyatının tahmini için geliştirilen NARX'in eğitim durumu (eğitim algoritması: LM, model: 49-(2)-10-1)

Eğitilmiş ağıın eğitim ve test hatalarından oluşan bir hata histogramı Şekil 4.54'te gösterilmiştir. Şekil incelendiğinde hataların çoğunun  $\pm 3E-05$  aralığında olduğu ve maksimum hatanın yaklaşık olarak  $8E-05$  olduğu tespit edilebilir. Ayrıca sıfır hata noktası  $-1,5E-06$  merkezli tanımlanmış bölmenin altına düşmektedir. Bu nedenle, elde edilen




hataya bağılı olarak, eğitilmiş ağ, yatırım fonu kapanış fiyatının tahmini için gönül rahatlığıyla kullanılabilir.




**Şekil 4.54.** Fon portföy dağılımı ile IST'nin kapanış fiyatının tahmini için geliştirilen NARX'in hata histogramı (eğitim algoritması: LM, model: 49-(2)-10-1)

Ağın gerçekleşen değerler ile tahmin edilen değerler arasındaki regresyon grafiği Şekil 4.55'te gösterilmiştir. Şekilden de görüldüğü üzere NARX modelinin eğitim, doğrulama, test ve tüm veriler için elde edilen korelasyon katsayısı değerleri 1'e eşittir. Bu durum, elde edilen tahmin modelinin çıktılarının gerçekleşen çıktı değerleriyle uyum içinde olduğu ve bu değerler arasında sapma olmadığı anlamına gelmektedir.




**Şekil 4.55.** Fon portföy dağılımı ile IST'nin kapanış fiyatının tahmini için geliştirilen NARX'in regresyon grafikleri (eğitim algoritması: LM, model: 49-(2)-10-1)

Şekil 4.56, eğitilmiş çıktı değeri ile hedeflenen (gerçekleşen) değerlerin karşılaştırmasını göstermektedir. Bu değerler arasındaki fark  $-10E-05$  ile  $5E-05$  aralığında dağılmaktadır. Bu da hatanın az olduğunu ve tahminin güçlü bir şekilde gerçekleştiğini işaret etmektedir.




**Şekil 4.56.** Fon portföy dağılımı ile IST'nin kapanış fiyatının tahmini için geliştirilen NARX'in tahmin sonuçları (eğitim algoritması: LM, model: 49-(2)-10-1)

Şekil 4.57, hata otokorelasyon fonksiyonunu göstermekte ve tahmin hatalarının zamanla nasıl ilişkili olduğunu açıklamaktadır. Şekilde, sıfır gecikmeli korelasyon dışındaki korelasyonlar, %95 güven sınırları içinde kalmamasına rağmen sıfır etrafında dalgalanmaktadır. Bu nedenle model yeterli görülmektedir.



**Şekil 4.57.** Fon portföy dağılımı ile IST'nin kapanış fiyatının tahmini için geliştirilen NARX'in hata otokorelasyonları (eğitim algoritması: LM, model: 49-(2)-10-1)

Şekil 4.58’de gösterilen girdi-hata çapraz korelasyon fonksiyonunda, tüm korelasyonlar güven sınırları içindedir. Bu da yeterli bir tahmin modelinin olduğunu göstermektedir.



Şekil 4.58. Fon portföy dağılımı ile IST’nin kapanış fiyatının tahmini için geliştirilen NARX’in girdi-hata çapraz-korelasyonları (eğitim algoritması: LM, model: 49-(2)-10-1)

#### 4.1.3. Yatırım fonu kapanış fiyatının fon portföy dağılımından faydalanılarak tahmin edilmesi için geliştirilen modellerin yeni tarihli veriler ile ek testlere tabi tutulması

Yatırım fonu kapanış fiyatının fon portföy dağılımından faydalanılarak tahmin edilmesi için geliştirilen tek gizli katmanlı YSA, iki gizli katmanlı YSA ve NARX modelleri yeni tarihli veriler ile ek testlere tabi tutularak modellerin istikrarlı bir şekilde çalışması durumu kontrol edilmiştir.


##### 4.1.3.1. En fazla sayıda portföye dağılan yatırım fonuna ilişkin bulgular

DBP’nin kapanış fiyatının fon portföy dağılımından faydalanılarak tahmin edilmesi için geliştirilen tek gizli katmanlı YSA, iki gizli katmanlı YSA ve NARX modellerinden optimal sonuç veren modellere ilişkin bilgiler Çizelge 4.39’da gösterilmiştir.


**Çizelge 4.39.** DBP'nin kapanış fiyatının fon portföy dağılımından faydalanılarak tahmin edilmesi için geliştirilen ve optimal sonuç veren tek gizli katmanlı YSA, iki gizli katmanlı YSA ve NARX model mimarileri

Yöntem	Optimal Sonucu Veren	
	Eğitim Algoritması	Model
YSA-1	BR	49-10-1
YSA-2	BR	49-5-10-1
NARX	BR	49-(1)-5-1


Geliştirilen modellerin ek testlere tabi tutulması için DBP yatırım fonunun 2021 yılı Temmuz-Aralık dönemindeki 125 iş gününe ait verilerinden yararlanılmıştır. DBP yatırım fonu için 125 iş gününe ait kapanış fiyatlarıyla, optimal sonuç veren tek gizli katmanlı YSA, iki gizli katmanlı YSA ve NARX model mimarileri yardımıyla elde edilen kapanış fiyatı tahminleri arasındaki ilişki sırasıyla Şekil 4.59, Şekil 4.60 ve Şekil 4.61'de gösterilmiştir.



**Şekil 4.59.** Fon portföy dağılımı ile DBP'nin kapanış fiyatının tahmini için geliştirilen ve optimal sonuç veren tek gizli katmanlı YSA'nın ek testi sonrasında elde edilen tahmin sonuçları (eğitim algoritması: BR, model: 49-10-1)



**Şekil 4.60.** Fon portföy dağılımı ile DBP'nin kapanış fiyatının tahmini için geliştirilen ve optimal sonuç veren iki gizli katmanlı YSA'nın ek testi sonrasında elde edilen tahmin sonuçları (eğitim algoritması: BR, model: 49-5-10-1)



**Şekil 4.61.** Fon portföy dağılımı ile DBP'nin kapanış fiyatının tahmini için geliştirilen ve optimal sonuç veren NARX'in ek testi sonrasında elde edilen tahmin sonuçları (eğitim algoritması: BR, model: 49-(1)-5-1)

Şekiller incelendiğinde DBP'nin kapanış fiyatı tahmini hatalarının 79. işgünü itibariyle arttığı gözlenmektedir. Fon için 79. işgünü 27.10.2021 tarihine denk gelmektedir. Tahmin hatalarının artmasında majör makroekonomik değişikliklerin önemli etkisi olduğu düşünülmektedir. Majör makroekonomik değişikliklerde TCMB'nin politika faizinin 23.09.2021 tarihinde 100 baz puan indirerek %18'e, 21.10.2021 tarihinde 200 baz puan indirerek %16'ya, 18.11.2021 tarihinde 100 baz puan indirerek %15'e ve son olarak 16.12.2021'de 100 baz puan indirerek %14'e indirilmesi önemli yer tutmaktadır. TCMB'nin politika faizini indirmesi, birikimini vadeli mevduatta değerlendiren yatırımcıların borsa ve döviz yöneltmelerine sebep olmuştur. 23.09.2021 tarihindeki ilk faiz indirimi borsada ve döviz kurunda artış trendini başlatmış, sırasıyla 21.10.2021, 18.11.2021 ve 16.12.2021 tarihindeki faiz indirimleri artış trendinin ivmesini artırmıştır. Bu artış 20.12.2021 tarihinde "Kur Korunmalı Türk Lirası Vadeli Mevduat"ın duyurmasıyla borsada ve döviz kurunda ciddi bir düşüşe sebep olmuştur. Ayrıca politika faizinin düşmesi sonucunda döviz kurundaki meydana gelen artış, üreticilerin ara mallarındaki maliyet kalemlerinde artışa sebep olmuş ve bu durum satış fiyatlarında artışı tetikleyerek enflasyonun artmasını beraberinde getirmiştir. 2021 yılı itibariyle Türkiye'de gerçekleşen ithalatın ara mal grubuna dağılımı %77,2 olarak gerçekleşmiştir (Orkunoğlu Şahin, 2022). İlave testlerin yapıldığı 2021 yılının Temmuz, Ağustos, Eylül, Ekim, Kasım ve Aralık ayları için aylık Tüketici Fiyat Endeksi yüzdelik artışı sırasıyla 1,80, 1,12, 1,25, 2,39, 3,51 ve 13; aylık Üretici Fiyat Endeksi yüzdelik artışı ise sırasıyla 2,46, 2,77, 1,55, 5,24, 9,99 ve 19,08 olarak belirlenmiştir (TCMB, 2022a, 2022b). Yüksek enflasyon oranı ve döviz kurundan dolayı Türkiye'nin kredi risk priminde artış meydana gelmiş ve bu durum önce Devlet İç Borçlanma senetlerinin (devlet tahvili, hazine bonusu) ve domino etkisi ile birlikte özel sektör tahvilleri ile finansman bonolarının faizlerinin artmasına sebep olmuştur (Özçelik ve Göksu, 2020). DBP, ağırlıklı olarak yerli ve yabancı kamu ve özel sektör borçlanma araçlarına yatırım yapmaktadır. Portföy bileşimi nedeniyle DBP önceki dönemlere kıyasla daha fazla değerlendirilmiştir. Bundan dolayı ilave testin yapıldığı dönemdeki günlük kapanış fiyatlarındaki artış önceki dönemlere kıyasla daha yüksek olmuş ve tahmin doğruluğu olumsuz yönde etkilenmiştir. 2017, 2018, 2019, 2020 ve 2021 yılları için DBP'nin yüzdelik getirisi sırasıyla 11,58, 15,11, 24,66, 14,47 ve 27,75 olarak hesaplanmıştır (KAP, 2022).

DBP'nin 125 iş günlük periyot için ek testlere tabi tutulması sonucunda elde edilen performans ölçüt değerleri Çizelge 4.40'ta gösterilmiştir. Çizelgeden hareketle DBP yatırım fonunun kapanış fiyatının tahmininde NARX'in tek gizli katmanlı YSA ve iki gizli katmanlı YSA'ya kıyasla çok daha isabetli tahminler ürettiği sonucuna varılabilir.

**Çizelge 4.40.** DBP'nin 125 iş günlük yeni tarihli veri için tek gizli katmanlı YSA, iki gizli katmanlı YSA ve NARX ile ek testlere tabi tutulması sonucu elde edilen kapanış fiyatı tahminlerine ilişkin performans ölçüt değerleri

Yöntem	Performans Ölçütü				
	SSE	MSE	RMSE	MAE	MAPE
YSA-1	0,004671	3,74E-05	0,006113	0,003994	7,379288
YSA-2	0,011285	9,03E-05	0,009501	0,008211	15,94196
NARX	0,000319	2,55E-06	0,001598	0,000982	1,798583

#### 4.1.3.2. En çok işlem gören yatırım fonuna ilişkin bulgular

IST'nin kapanış fiyatının fon portföy dağılımından faydalanılarak tahmin edilmesi için geliştirilen tek gizli katmanlı YSA, iki gizli katmanlı YSA ve NARX modellerinden optimal sonuç veren modellere ilişkin bilgiler Çizelge 4.41 'de gösterilmiştir.


**Çizelge 4.41.** IST'nin kapanış fiyatının fon portföy dağılımından faydalanılarak tahmin edilmesi için geliştirilen ve optimal sonuç veren tek gizli katmanlı YSA, iki gizli katmanlı YSA ve NARX model mimarileri

Yöntem	Optimal Sonucu Veren	
	Eğitim Algoritması	Model
YSA-1	BR	49-10-1
YSA-2	BR	49-6-5-1
NARX	LM	49-(2)-10-1


Geliştirilen modellerin ek testlere tabi tutulması için IST yatırım fonunun 2021 yılı Temmuz-Aralık dönemindeki 125 iş gününe ait verilerinden yararlanılmıştır. IST yatırım fonu için 125 iş gününe ait kapanış fiyatlarıyla, optimal sonuç veren tek gizli katmanlı YSA, iki gizli katmanlı YSA ve NARX model mimarileri yardımıyla elde edilen kapanış




fiyatı tahminleri arasındaki ilişki sırasıyla Şekil 4.62, Şekil 4.63 ve Şekil 4.64'te gösterilmiştir.



**Şekil 4.62.** Fon portföy dağılımı ile IST'nin kapanış fiyatının tahmini için geliştirilen ve optimal sonuç veren tek gizli katmanlı YSA'nın ek testi sonrasında elde edilen tahmin sonuçları (eğitim algoritması: BR, model: 49-10-1)



**Şekil 4.63.** Fon portföy dağılımı ile IST'nin kapanış fiyatının tahmini için geliştirilen ve optimal sonuç veren iki gizli katmanlı YSA'nın ek testi sonrasında elde edilen tahmin sonuçları (eğitim algoritması: BR, model: 49-6-5-1)



**Şekil 4.64.** Fon portföy dağılımı ile IST'nin kapanış fiyatının tahmini için geliştirilen ve optimal sonuç veren NARX'in ek testi sonrasında elde edilen tahmin sonuçları (eğitim algoritması: LM, model: 49-(2)-10-1)

IST'nin risk değeri 2'dir. Risk skalası 1 ile 7 arasında değer almaktadır. Risk skalasında risk, risk değerinin artması ile artmaktadır. Buradan hareketle fonun düşük derecede riskli olduğu ve ekonomideki hareketlilikten minimum düzeyde etkilenebileceği çıkarımı yapılabilir. Ekonomide değişkenlik fon portföyünün dağılım stratejisinin kimi dönemlerde sınırlamalar dahilinde etkin bir şekilde değiştirilmesine yol açarak tahmin hatalarının oluşumuna neden olmuştur.

IST'nin 125 iş günlük periyot için ek testlere tabi tutulması sonucunda elde edilen performans ölçüt değerleri Çizelge 4.42'de gösterilmiştir. Çizelgeden hareketle IST yatırım fonunun kapanış fiyatının tahmininde NARX'in tek gizli katmanlı YSA ve iki gizli katmanlı YSA'ya kıyasla daha isabetli tahminler ürettiği sonucuna varılabilir.

**Çizelge 4.42.** IST'nin 125 iş günlük yeni tarihli veri için tek gizli katmanlı YSA, iki gizli katmanlı YSA ve NARX ile ek testlere tabi tutulması sonucu elde edilen kapanış fiyatı tahminlerine ilişkin performans ölçüt değerleri

Yöntem	Performans Ölçütü				
	SSE	MSE	RMSE	MAE	MAPE
YSA-1	0,002297	1,84E-05	0,004287	0,003478	9,392311
YSA-2	0,027148	2,17E-04	0,014737	0,010284	27,76336
NARX	0,001077	8,62E-06	0,002936	0,000884	2,389777

#### **4.2. Yatırım Fonu Kapanış Fiyatının Performans Değerlendirme Yöntemleri Değerlerinden Faydalanılarak Tahmin Edilmesi**

Profesyonel olarak yönetilen yatırım fonlarının başarılı bir şekilde yönetilip yönetilmediğinin belirlenmesi gerekmektedir. Fonların başarılı bir şekilde yönetilip yönetilmediği ise performanslarının ölçülmesiyle anlaşılmaktadır (Korkmaz ve Uygurtürk, 2007b). Bu başlık altında, yatırım fonu kapanış fiyatının tahmin edilmesini sağlamak amacıyla, ilgili yatırım fonunun geçmiş performans değerlendirme yöntemleri ile elde edilmiş değerlerden faydalanılmıştır. Bu sayede bir yatırım fonunun gelecekte başarılı olup olamayacağı ve ne kadar başarılı olacağı üzerine görüş bildirilebilecek ve bu donelere göre başarılı fonlar belirlenebilecektir.

Çalışmaya ait veri seti, Finnet Analiz Expert programından elde edilmiştir. Finnet Analiz Expert, Türkiye sermaye piyasası araçlarına ilişkin, detaylı veri setlerinin, excel ortamında kullanılabilmesine ve kolayca raporlamalar yapılabilmesine imkân sağlayan, finansal analiz programıdır (Finnet, 2021). Programdan 2017-2021/6 yılları arasında işlem gören DBP ve IST fonlarına ilişkin tarih, günlük kapanış fiyatı, Beta, Standart sapma, Jensen alfa, Sharpe oranı, Treynor oranı, Enformasyon oranı, Sortino oranı, Upside capture ratio ve Downside capture ratio gibi günlük sayısal bilgiler toplanmıştır. Sortino oranı DBP fonu için ilgili tarih aralığında tüm günler için elde edilebilse de IST fonu için 04.10.2018 ve sonrası için elde edilememektedir. Bundan dolayı Sortino ölçütü çalışmadan çıkarılmıştır. Bunun yanı sıra Downside capture ratio IST fonu için 22.03.2021 ve sonrası için, DBP fonu içinse 17.12.2019 ve sonrası için elde edilememektedir. Bu durumdan dolayı Downside capture ratio ve buna bağlı olarak da

Upside capture ratio çalışmadan çıkarılmıştır. Elde edilen veri seti, en fazla sayıda portföy kalemine dağılan ve en fazla işlem hacmine sahip iki fon için 1128 iş günlük bir zaman serisinden oluşmaktadır.

Tez çalışmasında yatırım fonu kapanış fiyatının performans değerlendirme yöntemleri değerlerinden faydalanılarak tahmin edilmesi için tek gizli katmanlı YSA, iki gizli katmanlı YSA ve NARX model mimarileri geliştirilmiştir. Geliştirilen mimarilerde gizli katman nöron sayısı 1 ile 10 arasında sınırlandırılmıştır. Yapılan analizlerde gizli katman nöron sayısının 10 kat artması (1 ile 100 arasında sınırlandırılması) toplam analiz sayısının 12600'den 1206000'e yükselmesine yol açmaktadır. Ayrıca gizli katman nöron sayısının artması ile birim analiz süresi uzamakta ve bu durum toplam analiz süresinin analiz sayısı ile doğrusal olarak artış göstermesinin önüne geçmektedir. Bu özel duruma rağmen analiz sayısının artışıyla toplam analiz süresinin doğrusal bir artış gösterdiği varsayılırsa gizli katman nöron sayısının 10 kat artması toplam analiz süresinin 95 kat artmasına sebep olmaktadır.

#### **4.2.1. Yatırım fonu kapanış fiyatının performans değerlendirme yöntemleri değerlerinden faydalanılarak tahmin edilmesi için YSA model mimarilerinin geliştirilmesi**

Bir YSA probleminin çözümünde kullanılan ağ modelinin yapısı girdi sayısı, çıktı sayısı, girdi katmanı – gizli katman – çıktı katmanı arasındaki aktivasyon fonksiyonları, verinin eğitim – doğrulama – test dağılımı oranı, eğitim tur sayısı ve hata hedefi gibi parametreleri içermektedir. Çalışmada YSA'yı eğitmek için LM, BR ve SCG eğitim algoritmalarından faydalanılmıştır. Önerilen ağ modelinin tasarımında kullanılan parametreler, analizde faydalanılan eğitim algoritmalarına göre Çizelge 4.43'teki gibi sınıflandırılmıştır.

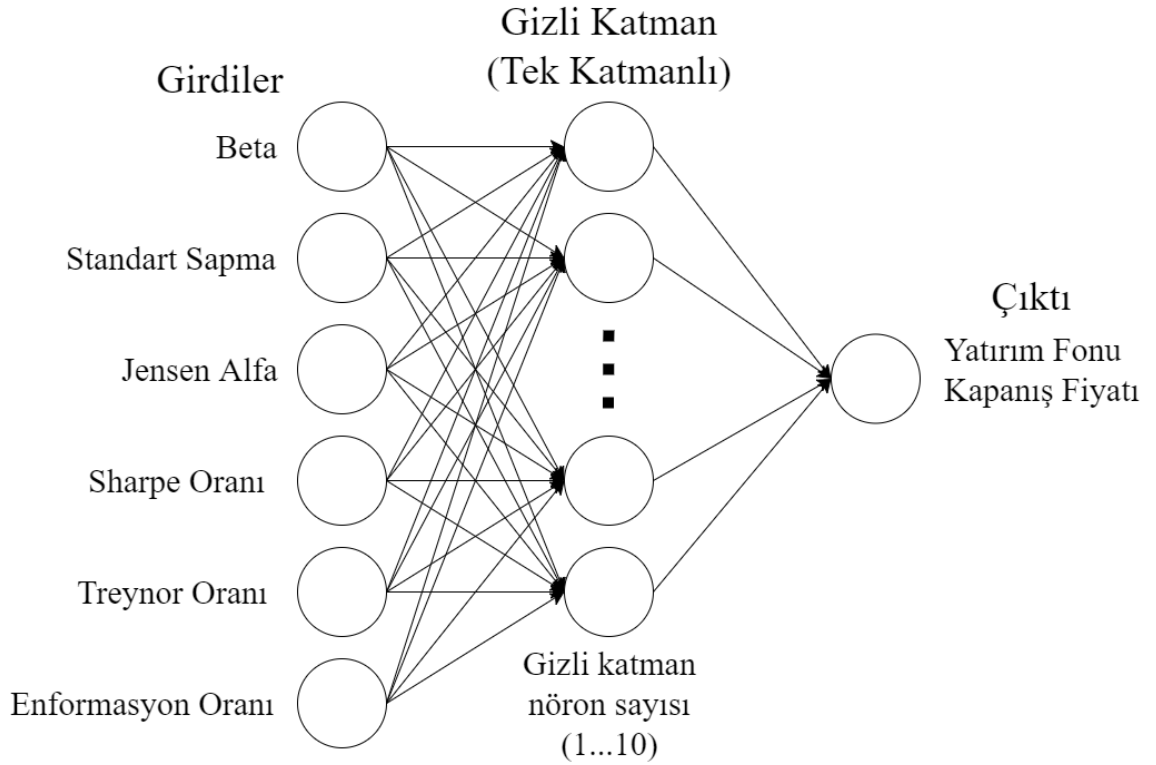
İlgili menkul kıymet yatırım fonlarının günlük kapanış fiyatının tahminini yapmak amacıyla girdi olarak DBP ve IST menkul kıymet yatırım fonları için elde edilebilen Beta, Standart sapma, Jensen alfa, Sharpe oranı, Treynor oranı ve Enformasyon oranı olmak üzere 6 tane risk ve performans ölçütünden faydalanılmıştır. Çıktı ise ilgili fonların günlük kapanış fiyatlarıdır.

**Çizelge 4.43.** YSA algoritmasının tasarım parametreleri

Ağ parametreleri		Eğitim algoritmaları		
		LM	BR	SCG
Girdi sayısı		6	6	6
Çıktı sayısı		1	1	1
Aktivasyon fonksiyonu	Girdi-Gizli	Hiperbolik tanjant sigmoid	Hiperbolik tanjant sigmoid	Hiperbolik tanjant sigmoid
	Gizli-Çıktı	Lineer	Lineer	Lineer
Veri bölme	Eğitim	%70	%85	%70
	Doğrulama	%15	-	%15
	Test	%15	%15	%15
Eğitim tur sayısı		1000	1000	1000
Performans hedefi		0	0	0
Başlangıç mu değeri		0,005	0,001	-
mu için indirgeme faktörü		0,1	0,1	-
mu için çoğaltma faktörü		10	10	-
mu için maksimum değer		1e10	1e10	-
Maksimum doğrulama hatası		0	6	6
Minimum performans gradyanı		1e-7	1e-7	1e-6
Sigma		-	-	5e-5
Lambda		-	-	5e-7

**4.2.1.1. Yatırım fonu kapanış fiyatının performans değerlendirme yöntemleri değerlerinden faydalanılarak tahmin edilmesi için geliştirilen tek gizli katmanlı YSA model mimarileri**

Yatırım fonlarının kapanış fiyatının performans değerlendirme yöntemleri değerlerinden faydalanılarak tahmin edilmesi için geliştirilen tek gizli katmanlı YSA mimarisi Şekil 4.65'te gösterilmiştir. Yatırım fonu kapanış fiyatının performans değerlendirme yöntemleri değerlerinden faydalanılarak tahmin edilmesi için geliştirilen tek gizli katmanlı YSA model mimarisine örnek olarak 6-2-1 gösterimi verilebilir. Gösterimde 6 sayısı girdi sayısını, 2 sayısı gizli katman nöron sayısını ve 1 sayısı çıktı sayısını temsil etmektedir.



**Şekil 4.65.** Yatırım fonu kapanış fiyatının performans değerlendirme yöntemleri değerlerinden faydalanılarak tahmin edilmesi için geliştirilen tek gizli katmanlı YSA model mimarisi

Tek gizli katmanlı YSA modelinin çözümünde, üç farklı eğitim algoritması kullanılarak ve gizli katman büyüklüğü 1 ile 10 arasında değiştirilerek, her bir fon için toplam 30 farklı ağ yapısı oluşturulmuştur. Bu 30 farklı ağ yapısı için analiz 10 kez tekrarlanmış ve her bir fon için 300 olmak üzere toplam 600 analiz gerçekleştirilmiştir.

Tek gizli katmanlı YSA modelini eğittikten sonra, modelin tahmininin doğruluğunu değerlendirmek için SSE, MSE, RMSE, MAE, MAPE, R ve  $R^2$  performans ölçütlerinden faydalanılmıştır.

#### 4.2.1.1.1. En fazla sayıda portföye dağılan yatırıma fonuna ilişkin bulgular

DBP'nin kapanış fiyatının, fonun performans değerlendirme yöntemleri değerleriyle tahmin edilmesi için geliştirilen tüm tek gizli katmanlı YSA model mimarilerinin eğitimi sonucunda elde edilen performans ölçütlerine ilişkin ortalama, standart sapma, en büyük ve en küçük değerler Çizelge 4.44'te gösterilmiştir.

**Çizelge 4.44.** DBP'nin performans değerlendirme yöntemleri değerlerinin tek gizli katmanlı YSA ile eğitimi sonucu elde edilen kapanış fiyatı tahminine ilişkin performans ölçüt değerleri

Performans Ölçütleri		SSE	MSE	RMSE	MAE	MAPE	R	R <sup>2</sup>
BR	Ortalama	2,16E-05	2,25E-08	1,45E-04	1,08E-04	0,319186	0,999746	0,999491
	St. Sapma	1,25E-05	1,30E-08	3,83E-05	3,05E-05	0,085874	0,000147	0,000294
	En Büyük	5,46E-05	5,70E-08	2,39E-04	1,82E-04	0,524362	<b>0,999921</b>	<b>0,999843</b>
	En Küçük	6,61E-06	<b>6,89E-09</b>	<b>8,30E-05</b>	<b>6,06E-05</b>	<b>0,182375</b>	0,999352	0,998704
LM	Ortalama	1,76E-05	2,23E-08	1,42E-04	1,06E-04	0,311629	0,999748	0,999497
	St. Sapma	1,19E-05	1,51E-08	4,54E-05	3,53E-05	0,099325	0,000171	0,000341
	En Büyük	4,66E-05	5,90E-08	2,43E-04	1,85E-04	0,534008	0,999921	0,999842
	En Küçük	<b>5,48E-06</b>	6,94E-09	8,33E-05	6,14E-05	0,183177	0,999322	0,998645
SCG	Ortalama	2,53E-04	3,20E-07	5,48E-04	4,17E-04	1,196560	0,996397	0,992811
	St. Sapma	1,47E-04	1,86E-07	1,39E-04	1,09E-04	0,310635	0,002101	0,004172
	En Büyük	1,29E-03	1,63E-06	1,28E-03	9,73E-04	2,655164	0,999054	0,998108
	En Küçük	6,74E-05	8,53E-08	2,92E-04	2,34E-04	0,659446	0,981701	0,963737

DBP'nin performans değerlendirme yöntemleri değerlerinin tek gizli katmanlı YSA ile eğitimi sonucu elde edilen performans ölçütlerinden MSE, RMSE, MAE, MAPE, R ve R<sup>2</sup> için en iyi değerlere BR eğitim algoritmasına ve 6-7-1 model mimarisine sahip ağda ulaşılmıştır. En iyi SSE değerine ise LM eğitim algoritmasına ve 6-10-1 model mimarisine sahip ağda ulaşılmıştır.

DBP'nin kapanış fiyatının, fonun performans değerlendirme yöntemleri değerleriyle tahmin edilmesi için geliştirilen tüm tek gizli katmanlı YSA model mimarilerinin doğrulanması sonucunda elde edilen performans ölçütlerine ilişkin ortalama, standart sapma, en büyük ve en küçük değerler Çizelge 4.45'te gösterilmiştir.

**Çizelge 4.45.** DBP'nin performans değerlendirme yöntemleri değerlerinin tek gizli katmanlı YSA ile doğrulanması sonucu elde edilen kapanış fiyatı tahminine ilişkin performans ölçüt değerleri

Performans Ölçütleri		SSE	MSE	RMSE	MAE	MAPE	R	R <sup>2</sup>
BR	Ortalama	-	-	-	-	-	-	-
	St. Sapma	-	-	-	-	-	-	-
	En Büyük	-	-	-	-	-	-	-
	En Küçük	-	-	-	-	-	-	-
LM	Ortalama	3,90E-06	2,31E-08	1,46E-04	1,09E-04	0,320487	0,999739	0,999479
	St. Sapma	2,45E-06	1,45E-08	4,32E-05	3,37E-05	0,094985	0,000167	0,000333
	En Büyük	1,15E-05	6,81E-08	2,61E-04	2,03E-04	0,583852	<b>0,999925</b>	<b>0,999850</b>
	En Küçük	<b>1,23E-06</b>	<b>7,29E-09</b>	<b>8,54E-05</b>	<b>6,81E-05</b>	<b>0,201030</b>	0,999258	0,998517
SCG	Ortalama	5,46E-05	3,23E-07	5,50E-04	4,21E-04	1,213574	0,996309	0,992635
	St. Sapma	2,97E-05	1,76E-07	1,42E-04	1,11E-04	0,320611	0,002090	0,004155
	En Büyük	2,14E-04	1,27E-06	1,13E-03	8,68E-04	2,410948	0,999060	0,998122
	En Küçük	1,33E-05	7,86E-08	2,80E-04	2,14E-04	0,606568	0,984649	0,969534

DBP'nin performans değerlendirme yöntemleri değerlerinin tek gizli katmanlı YSA ile doğrulanması sonucu elde edilen performans ölçütlerinden SSE, MSE, RMSE, R ve R<sup>2</sup> için en iyi değerlere LM eğitim algoritmasına ve 6-10-1 model mimarisine sahip ağda ulaşılmıştır. En iyi MAE değerine LM eğitim algoritmasına ve 6-8-1 model mimarisine sahip ağda, en iyi MAPE değerine diğer bir LM eğitim algoritmasına ve 6-10-1 model mimarisine sahip ağda ulaşılmıştır.


DBP'nin kapanış fiyatının, fonun performans değerlendirme yöntemleri değerleriyle tahmin edilmesi için geliştirilen tüm tek gizli katmanlı YSA model mimarilerinin test edilmesi sonucunda elde edilen performans ölçütlerine ilişkin ortalama, standart sapma, en büyük ve en küçük değerler Çizelge 4.46'da gösterilmiştir. Geliştirilen tüm tek gizli katmanlı YSA mimarilerinin test edilmesi sonucunda elde edilen en iyi MSE, MAPE ve R performans ölçüt değerlerinin gizli katman nöron sayısına göre değişimi ise sırasıyla Şekil 4.66, Şekil 4.67 ve Şekil 4.68'de gösterilmiştir.




**Çizelge 4.46.** DBP'nin performans değerlendirme yöntemleri değerlerinin tek gizli katmanlı YSA ile test edilmesi sonucu elde edilen kapanış fiyatı tahminine ilişkin performans ölçüt değerleri

Performans Ölçütleri		SSE	MSE	RMSE	MAE	MAPE	R	R <sup>2</sup>
BR	Ortalama	3,94E-06	2,33E-08	1,47E-04	1,10E-04	0,324226	0,999735	0,999471
	St. Sapma	2,39E-06	1,41E-08	4,05E-05	3,25E-05	0,091794	0,000162	0,000324
	En Büyük	1,35E-05	7,96E-08	2,82E-04	2,17E-04	0,611079	<b>0,999934</b>	<b>0,999868</b>
	En Küçük	<b>1,04E-06</b>	<b>6,18E-09</b>	<b>7,86E-05</b>	<b>5,66E-05</b>	<b>0,168420</b>	0,999117	0,998234
LM	Ortalama	3,95E-06	2,34E-08	1,46E-04	1,09E-04	0,322566	0,999734	0,999469
	St. Sapma	2,59E-06	1,54E-08	4,54E-05	3,56E-05	0,100842	0,000174	0,000348
	En Büyük	1,12E-05	6,64E-08	2,58E-04	2,02E-04	0,589537	0,999932	0,999864
	En Küçük	1,10E-06	6,52E-09	8,07E-05	6,17E-05	0,189870	0,999237	0,998475
SCG	Ortalama	5,45E-05	3,22E-07	5,47E-04	4,19E-04	1,204220	0,996387	0,992793
	St. Sapma	3,50E-05	2,07E-07	1,51E-04	1,15E-04	0,325318	0,002381	0,004721
	En Büyük	3,08E-04	1,82E-06	1,35E-03	9,89E-04	2,678312	0,999129	0,998260
	En Küçük	1,37E-05	8,11E-08	2,85E-04	2,29E-04	0,665805	0,978652	0,957759


DBP'nin performans değerlendirme yöntemleri değerlerinin tek gizli katmanlı YSA ile test edilmesi sonucu elde edilen performans ölçütlerinin tamamı için en iyi değerlere BR eğitim algoritmasına ve 6-7-1 model mimarisine sahip ağda ulaşılmıştır.



**Şekil 4.66.** Performans değerlendirme yöntemleri değerleri ile DBP'nin kapanış fiyatının tahmini için geliştirilen her bir tek gizli katmanlı YSA model mimarisi için gerçekleştirilen test iterasyonları sonucunda elde edilen en iyi MSE değerleri



**Şekil 4.67.** Performans değerlendirme yöntemleri değerleri ile DBP'nin kapanış fiyatının tahmini için geliştirilen her bir tek gizli katmanlı YSA model mimarisi için gerçekleştirilen test iterasyonları sonucunda elde edilen en iyi MAPE değerleri



**Şekil 4.68.** Performans değerlendirme yöntemleri değerleri ile DBP'nin kapanış fiyatının tahmini için geliştirilen her bir tek gizli katmanlı YSA model mimarisi için gerçekleştirilen test iterasyonları sonucunda elde edilen en iyi R değerleri

6-7-1 model mimarisine sahip tek gizli katmanlı YSA’da eğitim algoritması çeşidine göre elde edilen eğitim, doğrulama ve test performans ölçüt sonuçları sırasıyla Çizelge 4.47, Çizelge 4.48 ve Çizelge 4.49’da gösterilmiştir.

**Çizelge 4.47.** DBP’nin performans değerlendirme yöntemleri değerlerinin tek gizli katmanlı YSA ile eğitimi sonucu elde edilen kapanış fiyatı tahminine ilişkin performans ölçüt değerleri (model: 6-7-1)

Performans Ölçütleri	Eğitim Algoritması		
	BR	LM	SCG
SSE	6,61E-06	7,18E-06	9,65E-05
MSE	6,89E-09	9,08E-09	1,22E-07
RMSE	8,30E-05	9,53E-05	3,49E-04
MAE	6,06E-05	6,95E-05	2,61E-04
MAPE	0,182375	0,211824	0,784505
R	0,999921	0,999895	0,998630
R <sup>2</sup>	0,999843	0,999791	0,997261


**Çizelge 4.48.** DBP’nin performans değerlendirme yöntemleri değerlerinin tek gizli katmanlı YSA ile doğrulanması sonucu elde edilen kapanış fiyatı tahminine ilişkin performans ölçüt değerleri (model: 6-7-1)

Performans Ölçütleri	Eğitim Algoritması		
	BR	LM	SCG
SSE	-	1,92E-06	1,99E-05
MSE	-	1,14E-08	1,18E-07
RMSE	-	1,07E-04	3,43E-04
MAE	-	7,65E-05	2,64E-04
MAPE	-	0,227957	0,783597
R	-	0,999876	0,998659
R <sup>2</sup>	-	0,999751	0,997319

**Çizelge 4.49.** DBP'nin performans değerlendirme yöntemleri değerlerinin tek gizli katmanlı YSA ile test edilmesi sonucu elde edilen kapanış fiyatı tahminine ilişkin performans ölçüt değerleri (model: 6-7-1)


Performans Ölçütleri	Eğitim Algoritması		
	BR	LM	SCG
SSE	1,04E-06	1,56E-06	1,76E-05
MSE	6,18E-09	9,20E-09	1,04E-07
RMSE	7,86E-05	9,59E-05	3,22E-04
MAE	5,66E-05	7,41E-05	2,46E-04
MAPE	0,168420	0,224608	0,734079
R	0,999934	0,999901	0,998796
R <sup>2</sup>	0,999868	0,999802	0,997593

İlgili model mimarisi Şekil 4.69'da gösterilmiştir.




**Şekil 4.69.** Performans değerlendirme yöntemleri değerleri ile DBP'nin kapanış fiyatının tahmini için geliştirilen tek gizli katmanlı YSA model mimarisi (eğitim algoritması: BR, model: 6-7-1)

Performans ölçütlerinden MSE'nin eğitim ve test için performansı Şekil 4.70'te gösterilmektedir. Şekilde en iyi eğitim performansının 6,8906E-09 MSE ile 40. eğitim turunda elde edildiği görülmektedir.




**Şekil 4.70.** Performans değerlendirme yöntemleri değerleri ile DBP'nin kapanış fiyatının tahmini için geliştirilen tek gizli katmanlı YSA'nın MSE Performansı (eğitim algoritması: BR, model: 6-7-1)

Şekil 4.71, DBP'nin performans değerlendirme yöntemleri değerleri ile kapanış fiyatının tahminine ilişkin tek gizli katmanlı YSA'nın eğitim durumunu özetlemektedir.




**Şekil 4.71.** Performans değerlendirme yöntemleri değerleri ile DBP'nin kapanış fiyatının tahmini için geliştirilen tek gizli katmanlı YSA'nın eğitim durumu (eğitim algoritması: BR, model: 6-7-1)

Eđitilmiş ađın eđitim ve test hatalarından oluřan bir hata histogramı Őekil 4.72’de gsterilmiřtir. Őekil incelendiđinde hataların ođunun  $\pm 0,00015$  aralıđında olduđu ve maksimum hatanın yaklařık olarak 0,0003 olduđu tespit edilebilir. Ayrıca sıfır hata noktası  $-2,4E-05$  merkezli tanımlanmıř blmenin altına dřmektedir.



**Őekil 4.72.** Performans deđerlendirme yntemleri deđerleri ile DBP’nin kapanıř fiyatının tahmini iin geliřtirilen tek gizli katmanlı YSA’nın hata histogramı (eđitim algoritması: BR, model: 6-7-1)

Ađın gerekleřen ve tahmin edilen deđerler arasındaki regresyon grafiđi Őekil 4.73’te gsterilmiřtir. Őekilde grldđ gibi tek gizli katmanlı YSA modelinin eđitim ve test iin korelasyon katsayısı deđerleri sırasıyla 0,99992 ve 0,99993’tr. Ayrıca tm veriler iin elde edilen korelasyon katsayısı deđerinin 0,99992 olması, elde edilen tahmin modelinin ıktılarının gerekleřen ıktı deđerleriyle uyum iinde olduđu ve bu deđerler arasında sapma olmadıđı anlamına gelmektedir.



**Şekil 4.73.** Performans değerlendirme yöntemleri değerleri ile DBP'nin kapanış fiyatının tahmini için geliştirilen tek gizli katmanlı YSA'nın regresyon grafikleri (eğitim algoritması: BR, model: 6-7-1)

#### 4.2.1.1.2. En çok işlem gören yatırım fonuna ilişkin bulgular

IST'nin kapanış fiyatının, fonun performans değerlendirme yöntemleri değerleriyle tahmin edilmesi için geliştirilen tüm tek gizli katmanlı YSA model mimarilerinin eğitimi sonucunda elde edilen performans ölçütlerine ilişkin ortalama, standart sapma, en büyük ve en küçük değerler Çizelge 4.50'de gösterilmiştir.

**Çizelge 4.50.** IST'nin performans değerlendirme yöntemleri değerlerinin tek gizli katmanlı YSA ile eğitimi sonucu elde edilen kapanış fiyatı tahminine ilişkin performans ölçüt değerleri

Performans Ölçütleri		SSE	MSE	RMSE	MAE	MAPE	R	R <sup>2</sup>
BR	Ortalama	2,77E-04	2,89E-07	3,49E-04	2,65E-04	1,127674	0,994610	0,989404
	St. Sapma	6,38E-04	6,66E-07	4,09E-04	3,10E-04	1,413705	0,012442	0,024378
	En Büyük	2,12E-03	2,21E-06	1,49E-03	1,14E-03	5,133315	0,999830	0,999659
	En Küçük	8,96E-06	9,34E-09	9,66E-05	7,21E-05	0,300202	0,958811	0,919319
LM	Ortalama	2,16E-04	2,73E-07	3,46E-04	2,64E-04	1,127802	0,994865	0,989899
	St. Sapma	4,99E-04	6,31E-07	3,92E-04	3,00E-04	1,362040	0,011916	0,023343
	En Büyük	1,76E-03	2,22E-06	1,49E-03	1,15E-03	5,122164	<b>0,999879</b>	<b>0,999757</b>
	En Küçük	<b>5,36E-06</b>	<b>6,79E-09</b>	<b>8,24E-05</b>	<b>6,25E-05</b>	<b>0,266834</b>	0,957850	0,917477
SCG	Ortalama	6,51E-04	8,24E-07	8,22E-04	6,51E-04	2,768898	0,984691	0,969884
	St. Sapma	6,84E-04	8,66E-07	3,85E-04	3,11E-04	1,424311	0,016358	0,031566
	En Büyük	4,43E-03	5,61E-06	2,37E-03	1,96E-03	8,245092	0,996772	0,993555
	En Küçük	1,41E-04	1,78E-07	4,22E-04	3,08E-04	1,194778	0,893751	0,798791

IST'nin performans değerlendirme yöntemleri değerlerinin tek gizli katmanlı YSA ile eğitimi sonucu elde edilen performans ölçütlerinin tamamı için en iyi değerlere LM eğitim algoritmasına ve 6-10-1 model mimarisine sahip ağda ulaşılmıştır.

IST'nin kapanış fiyatının, fonun performans değerlendirme yöntemleri değerleriyle tahmin edilmesi için geliştirilen tüm tek gizli katmanlı YSA model mimarilerinin doğrulanması sonucunda elde edilen performans ölçütlerine ilişkin ortalama, standart sapma, en büyük ve en küçük değerler Çizelge 4.51'de gösterilmiştir.



**Çizelge 4.51.** IST'nin performans değerlendirme yöntemleri değerlerinin tek gizli katmanlı YSA ile doğrulanması sonucu elde edilen kapanış fiyatı tahminine ilişkin performans ölçüt değerleri

Performans Ölçütleri		SSE	MSE	RMSE	MAE	MAPE	R	R <sup>2</sup>
BR	Ortalama	-	-	-	-	-	-	-
	St. Sapma	-	-	-	-	-	-	-
	En Büyük	-	-	-	-	-	-	-
	En Küçük	-	-	-	-	-	-	-
LM	Ortalama	4,75E-05	2,81E-07	3,57E-04	2,71E-04	1,163940	0,994881	0,989926
	St. Sapma	1,08E-04	6,41E-07	3,93E-04	3,00E-04	1,385195	0,011759	0,023037
	En Büyük	3,97E-04	2,35E-06	1,53E-03	1,17E-03	5,313614	<b>0,999811</b>	<b>0,999622</b>
	En Küçük	<b>1,81E-06</b>	<b>1,07E-08</b>	<b>1,04E-04</b>	<b>7,64E-05</b>	<b>0,325078</b>	0,954065	0,910239
SCG	Ortalama	1,37E-04	8,12E-07	8,20E-04	6,51E-04	2,758664	0,984970	0,970396
	St. Sapma	1,38E-04	8,18E-07	3,74E-04	3,03E-04	1,385317	0,015148	0,029402
	En Büyük	8,17E-04	4,84E-06	2,20E-03	1,83E-03	7,788377	0,996651	0,993313
	En Küçük	3,27E-05	1,94E-07	4,40E-04	3,34E-04	1,335241	0,915262	0,837705


IST'nin performans değerlendirme yöntemleri değerlerinin tek gizli katmanlı YSA ile doğrulanması sonucu elde edilen performans ölçütlerinden SSE, MSE, RMSE, R ve R<sup>2</sup> için en iyi değerlere LM eğitim algoritmasına ve 6-9-1 model mimarisine sahip ağda ulaşmıştır. En iyi MAE ve MAPE değerlerine ise LM eğitim algoritmasına ve 6-10-1 model mimarisine sahip ağda ulaşılmıştır.

IST'nin kapanış fiyatının, fonun performans değerlendirme yöntemleri değerleriyle tahmin edilmesi için geliştirilen tüm tek gizli katmanlı YSA model mimarilerinin test edilmesi sonucunda elde edilen performans ölçütlerine ilişkin ortalama, standart sapma, en büyük ve en küçük değerler Çizelge 4.52'de gösterilmiştir. Geliştirilen tüm tek gizli katmanlı YSA mimarilerinin test edilmesi sonucunda elde edilen en iyi MSE, MAPE ve R performans ölçüt değerlerinin gizli katman nöron sayısına göre değişimi ise sırasıyla Şekil 4.74, Şekil 4.75 ve Şekil 4.76'da gösterilmiştir.


**Çizelge 4.52.** IST'nin performans değerlendirme yöntemleri değerlerinin tek gizli katmanlı YSA ile test edilmesi sonucu elde edilen kapanış fiyatı tahminine ilişkin performans ölçüt değerleri

Performans Ölçütleri		SSE	MSE	RMSE	MAE	MAPE	R	R <sup>2</sup>
BR	Ortalama	4,69E-05	2,77E-07	3,49E-04	2,65E-04	1,125331	0,994852	0,989868
	St. Sapma	1,06E-04	6,28E-07	3,95E-04	3,00E-04	1,368483	0,011685	0,022920
	En Büyük	3,80E-04	2,25E-06	1,50E-03	1,16E-03	5,248952	<b>0,999823</b>	<b>0,999646</b>
	En Küçük	<b>1,65E-06</b>	<b>9,74E-09</b>	<b>9,87E-05</b>	7,66E-05	0,314404	0,957652	0,917097
LM	Ortalama	4,85E-05	2,87E-07	3,60E-04	2,75E-04	1,172205	0,994792	0,989755
	St. Sapma	1,11E-04	6,57E-07	3,97E-04	3,10E-04	1,409460	0,011952	0,023403
	En Büyük	4,11E-04	2,43E-06	1,56E-03	1,23E-03	5,495997	0,999806	0,999612
	En Küçük	1,93E-06	1,14E-08	1,07E-04	<b>7,44E-05</b>	<b>0,303293</b>	0,953772	0,909681
SCG	Ortalama	1,44E-04	8,51E-07	8,35E-04	6,62E-04	2,817263	0,984283	0,969133
	St. Sapma	1,56E-04	9,22E-07	3,92E-04	3,19E-04	1,469847	0,017891	0,034130
	En Büyük	1,09E-03	6,45E-06	2,54E-03	2,09E-03	8,870812	0,996950	0,993908
	En Küçük	3,01E-05	1,78E-07	4,22E-04	3,24E-04	1,260573	0,865392	0,748903


IST'nin performans değerlendirme yöntemleri değerlerinin tek gizli katmanlı YSA ile test edilmesi sonucu elde edilen performans ölçütlerinden SSE, MSE, RMSE, R ve R<sup>2</sup> için en iyi değerlere BR eğitim algoritmasına ve 6-10-1 model mimarisine sahip ağda ulaşılmıştır. En iyi MAE ve MAPE değerlerine ise LM eğitim algoritmasına ve 6-7-1 model mimarisine sahip ağda ulaşılmıştır. Genel olarak performans ölçüt değerleri incelendiğinde en iyi performansın BR eğitim algoritmasına ve 6-10-1 model mimarisine ait ağda ulaşıldığı sonucuna varılabilir.



**Şekil 4.74.** Performans değerlendirme yöntemleri değerleri ile IST'nin kapanış fiyatının tahmini için geliştirilen her bir tek gizli katmanlı YSA model mimarisi için gerçekleştirilen test iterasyonları sonucunda elde edilen en iyi MSE değerleri



**Şekil 4.75.** Performans değerlendirme yöntemleri değerleri ile IST'nin kapanış fiyatının tahmini için geliştirilen her bir tek gizli katmanlı YSA model mimarisi için gerçekleştirilen test iterasyonları sonucunda elde edilen en iyi MAPE değerleri



**Şekil 4.76.** Performans değerlendirme yöntemleri değerleri ile IST'nin kapanış fiyatının tahmini için geliştirilen her bir tek gizli katmanlı YSA model mimarisi için gerçekleştirilen test iterasyonları sonucunda elde edilen en iyi R değerleri

6-10-1 model mimarisine sahip YSA'da eğitim algoritması çeşidine göre elde edilen eğitim, doğrulama ve test performans ölçüt sonuçları sırasıyla Çizelge 4.53, Çizelge 4.54 ve Çizelge 4.55'te gösterilmiştir.

**Çizelge 4.53.** IST'nin performans değerlendirme yöntemleri değerlerinin tek gizli katmanlı YSA ile eğitimi sonucu elde edilen kapanış fiyatı tahminine ilişkin performans ölçüt değerleri (model: 6-10-1)

Performans Ölçütleri	Eğitim Algoritması		
	BR	LM	SCG
SSE	8,96E-06	8,89E-06	1,41E-04
MSE	9,34E-09	1,13E-08	1,78E-07
RMSE	9,66E-05	1,06E-04	4,22E-04
MAE	7,21E-05	7,57E-05	3,08E-04
MAPE	0,300202	0,311864	1,194778
R	0,999830	0,999796	0,996772
R <sup>2</sup>	0,999659	0,999592	0,993555


**Çizelge 4.54.** IST'nin performans değerlendirme yöntemleri değerlerinin tek gizli katmanlı YSA ile doğrulanması sonucu elde edilen kapanış fiyatı tahminine ilişkin performans ölçüt değerleri (model: 6-10-1)

Performans Ölçütleri	Eğitim Algoritması		
	BR	LM	SCG
SSE	-	2,41E-06	3,63E-05
MSE	-	1,42E-08	2,15E-07
RMSE	-	1,19E-04	4,63E-04
MAE	-	8,52E-05	3,46E-04
MAPE	-	0,340779	1,335241
R	-	0,999736	0,995685
R <sup>2</sup>	-	0,999472	0,991389

**Çizelge 4.55.** IST'nin performans değerlendirme yöntemleri değerlerinin tek gizli katmanlı YSA ile test edilmesi sonucu elde edilen kapanış fiyatı tahminine ilişkin performans ölçüt değerleri (model: 6-10-1)


Performans Ölçütleri	Eğitim Algoritması		
	BR	LM	SCG
SSE	1,65E-06	2,10E-06	3,10E-05
MSE	9,74E-09	1,25E-08	1,83E-07
RMSE	9,87E-05	1,12E-04	4,28E-04
MAE	7,66E-05	8,06E-05	3,26E-04
MAPE	0,314404	0,336058	1,260573
R	0,999823	0,999767	0,996801
R <sup>2</sup>	0,999646	0,999535	0,993611

İlgili model mimarisi Şekil 4.77'de gösterilmiştir.




**Şekil 4.77.** Performans değerlendirme yöntemleri değerleri ile IST'nin kapanış fiyatının tahmini için geliştirilen tek gizli katmanlı YSA model mimarisi (eğitim algoritması: BR, model: 6-10-1)

Performans ölçütlerinden MSE'nin eğitim ve test için performansı Şekil 4.78'de gösterilmektedir. Şekilden en iyi eğitim performansının  $9,3385E-09$  MSE ile 31. eğitim turunda elde edildiği sonucu çıkarılabilir.




**Şekil 4.78.** Performans değerlendirme yöntemleri değerleri ile IST'nin kapanış fiyatının tahmini için geliştirilen tek gizli katmanlı YSA'nın MSE performansı (eğitim algoritması: BR, model: 6-10-1)

Şekil 4.79, performans değerlendirme yöntemleri değerleri ile IST'nin kapanış fiyatının tahminine ilişkin geliştirilen ve optimal sonuç veren tek gizli katmanlı YSA'nın eğitim durumunu özetlemektedir.



**Şekil 4.79.** Performans değerlendirme yöntemleri değerleri ile IST'nin kapanış fiyatının tahmini için geliştirilen tek gizli katmanlı YSA'nın eğitim durumu (eğitim algoritması: BR, model: 6-10-1)


Eğitilmiş ağıın eğitim ve test hatalarından oluşan bir hata histogramı Şekil 4.80'de gösterilmiştir. Şekilde gösterilen hata histogramı, elde edilen veri uydurma hatalarının normal olarak yaklaşık sıfır hata (hedef-çıktı) gibi iyi bir aralıkta dağıldığını göstermektedir. Şekil incelendiğinde hataların çoğunun  $\pm 0,0001$  aralığında olduğu ve maksimum hatanın yaklaşık olarak  $0,0008$  olduğu tespit edilebilir. Ayrıca sıfır hata noktası  $-3,8E-05$  merkezli tanımlanmış bölmenin altına düşmektedir.



**Şekil 4.80.** Performans değerlendirme yöntemleri değerleri ile IST'nin kapanış fiyatının tahmini için geliştirilen tek gizli katmanlı YSA'nın hata histogramı (eğitim algoritması: BR, model: 6-10-1)

Ağın gerçekleşen ve tahmin edilen değerler arasındaki regresyon grafiği Şekil 4.81'de gösterilmiştir. Şekilde görüldüğü üzere tek gizli katmanlı YSA modelinin eğitim ve test için korelasyon katsayısı değerleri sırasıyla 0,99983 ve 0,99982'dir. Ayrıca tüm veriler için elde edilen korelasyon katsayısı değerinin 0,99983 olması, elde edilen tahmin modelinin çıktılarının gerçekleşen çıktı değerleriyle uyum içinde olduğu ve bu değerler arasında sapma olmadığı anlamına gelmektedir.



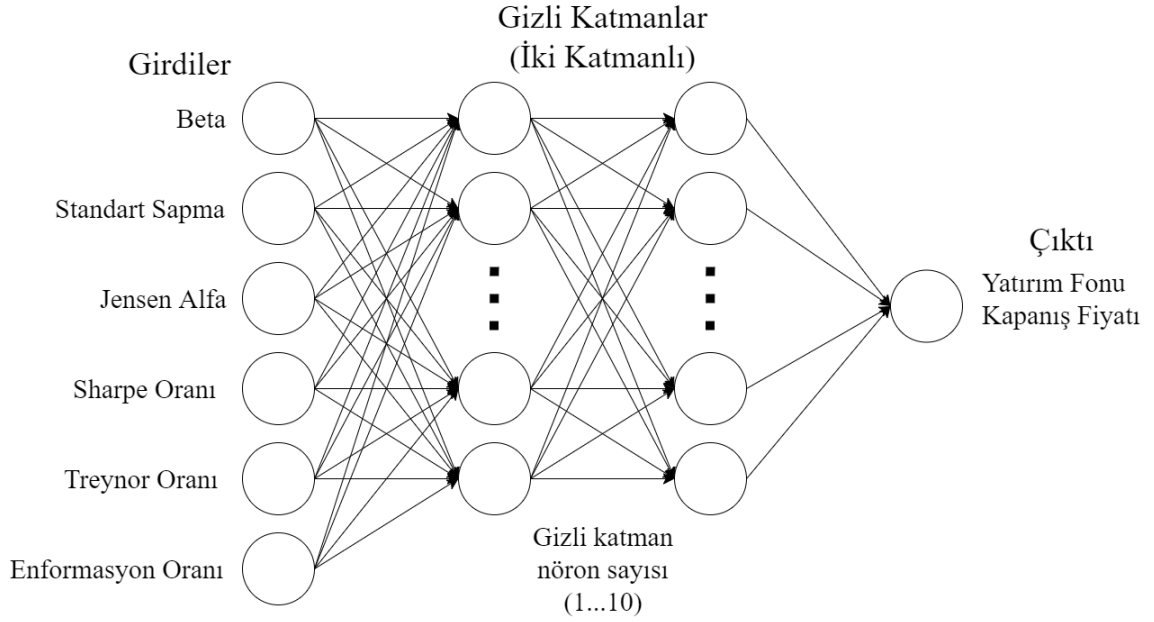


**Şekil 4.81.** Performans değerlendirme yöntemleri değerleri ile IST'nin kapanış fiyatının tahmini için geliştirilen tek gizli katmanlı YSA'nın regresyon grafikleri (eğitim algoritması: BR, model: 6-10-1)

#### 4.2.1.2. Yatırım fonu kapanış fiyatının performans değerlendirme yöntemleri değerlerinden faydalanılarak tahmin edilmesi için geliştirilen iki gizli katmanlı YSA model mimarileri

Yatırım fonlarının kapanış fiyatının performans değerlendirme yöntemleri değerlerinden faydalanılarak tahmin edilmesi için geliştirilen iki gizli katmanlı YSA mimarisi Şekil 4.82'de gösterilmiştir. Yatırım fonu kapanış fiyatının performans değerlendirme yöntemleri değerlerinden faydalanılarak tahmin edilmesi için geliştirilen iki gizli

katmanlı YSA model mimarisine örnek olarak 6-2-3-1 gösterimi verilebilir. Gösterimde 6 sayısı girdi sayısını, 2 sayısı ilk gizli katmanın nöron sayısını, 3 sayısı ikinci gizli katmanın nöron sayısını ve 1 sayısı çıktı sayısını temsil etmektedir.



**Şekil 4.82.** Yatırım fonu kapanış fiyatının performans değerlendirme yöntemleri değerlerinden faydalanılarak tahmin edilmesi için geliştirilen iki gizli katmanlı YSA model mimarisi

İki gizli katmanlı YSA modelinin çözümünde üç farklı eğitim algoritması kullanılarak ve her iki gizli katmanın büyüklüğü 1 ile 10 arasında değiştirilerek, her bir fon için toplamda 300 farklı ağ yapısı geliştirilmiştir. Bu 300 farklı ağ yapısı için analiz 10 kez tekrarlanmış ve her bir fon için 3000 olmak üzere toplam 6000 analiz gerçekleştirilmiştir.

İki gizli katmanlı YSA modelini eğittikten sonra, modelin tahmininin doğruluğunu değerlendirmek için SSE, MSE, RMSE, MAE, MAPE, R ve  $R^2$  performans ölçütlerinden faydalanılmıştır.

#### 4.2.1.2.1. En fazla sayıda portföye dağılan yatırım fonuna ilişkin bulgular

DBP'nin kapanış fiyatının, fonun performans değerlendirme yöntemleri değerleriyle tahmin edilmesi için geliştirilen tüm iki gizli katmanlı YSA model mimarilerinin eğitimi sonucunda elde edilen performans ölçütlerine ilişkin ortalama, standart sapma, en büyük ve en küçük değerler Çizelge 4.56'da gösterilmiştir.

**Çizelge 4.56.** DBP'nin performans değerlendirme yöntemleri değerlerinin iki gizli katmanlı YSA ile eğitimi sonucu elde edilen kapanış fiyatı tahminine ilişkin performans ölçüt değerleri

Performans Ölçütleri	SSE	MSE	RMSE	MAE	MAPE	R	R <sup>2</sup>	
BR	Ortalama	6,27E-05	6,54E-08	1,47E-04	1,07E-04	0,315875	0,999247	0,998520
	St. Sapma	4,14E-04	4,32E-07	2,09E-04	1,36E-04	0,392387	0,005035	0,009780
	En Büyük	7,04E-03	7,34E-06	2,71E-03	1,67E-03	4,769016	0,999962	0,999925
	En Küçük	3,16E-06	3,29E-09	5,74E-05	4,20E-05	0,125677	0,912522	0,832697
LM	Ortalama	1,77E-04	2,24E-07	1,98E-04	1,42E-04	0,421436	0,996886	0,994944
	St. Sapma	1,36E-03	1,72E-06	4,30E-04	3,14E-04	0,925157	0,034112	0,038865
	En Büyük	3,51E-02	4,44E-05	6,67E-03	5,97E-03	17,66298	<b>0,999977</b>	<b>0,999954</b>
	En Küçük	<b>1,60E-06</b>	<b>2,02E-09</b>	<b>4,50E-05</b>	<b>3,23E-05</b>	<b>0,099238</b>	-0,010460	0,000110
SCG	Ortalama	7,32E-04	9,26E-07	6,89E-04	5,22E-04	1,512715	0,987089	0,979702
	St. Sapma	3,07E-03	3,88E-06	6,72E-04	5,48E-04	1,617996	0,073192	0,081589
	En Büyük	3,54E-02	4,48E-05	6,70E-03	6,02E-03	17,85148	0,999305	0,998610
	En Küçük	5,00E-05	6,33E-08	2,52E-04	1,89E-04	0,534851	-0,285400	0,000479

DBP'nin performans değerlendirme yöntemleri değerlerinin iki gizli katmanlı YSA ile eğitimi sonucu elde edilen performans ölçütlerinden tamamı için en iyi değerlere LM eğitim algoritmasına ve 6-8-10-1 model mimarisine sahip ağda ulaşılmıştır.

DBP'nin kapanış fiyatının, fonun performans değerlendirme yöntemleri değerleriyle tahmin edilmesi için geliştirilen tüm iki gizli katmanlı YSA model mimarilerinin doğrulanması sonucunda elde edilen performans ölçütlerine ilişkin ortalama, standart sapma, en büyük ve en küçük değerler Çizelge 4.57'de gösterilmiştir.

**Çizelge 4.57.** DBP'nin performans değerlendirme yöntemleri değerlerinin iki gizli katmanlı YSA ile doğrulanması sonucu elde edilen kapanış fiyatı tahminine ilişkin performans ölçüt değerleri

Performans Ölçütleri		SSE	MSE	RMSE	MAE	MAPE	R	R <sup>2</sup>
BR	Ortalama	-	-	-	-	-	-	-
	St. Sapma	-	-	-	-	-	-	-
	En Büyük	-	-	-	-	-	-	-
	En Küçük	-	-	-	-	-	-	-
LM	Ortalama	4,02E-05	2,38E-07	2,03E-04	1,47E-04	0,433401	0,996719	0,994564
	St. Sapma	3,04E-04	1,80E-06	4,43E-04	3,21E-04	0,948792	0,033378	0,041682
	En Büyük	6,99E-03	4,14E-05	6,43E-03	5,81E-03	17,64882	<b>0,999980</b>	<b>0,999960</b>
	En Küçük	<b>3,07E-07</b>	<b>1,82E-09</b>	<b>4,26E-05</b>	<b>3,27E-05</b>	<b>0,099040</b>	0,059879	0,003586
SCG	Ortalama	1,57E-04	9,28E-07	6,88E-04	5,22E-04	1,514223	0,987306	0,979928
	St. Sapma	6,67E-04	3,95E-06	6,74E-04	5,50E-04	1,624845	0,071799	0,080756
	En Büyük	8,05E-03	4,77E-05	6,90E-03	6,24E-03	18,87224	0,999361	0,998722
	En Küçük	9,52E-06	5,63E-08	2,37E-04	1,73E-04	0,498989	-0,277000	0,000149


DBP'nin performans değerlendirme yöntemleri değerlerinin iki gizli katmanlı YSA ile doğrulanması sonucu elde edilen performans ölçütlerinin tamamı için en iyi değerlere LM eğitim algoritmasına ve 6-8-10-1 model mimarisine sahip ağda ulaşılmıştır.

DBP'nin kapanış fiyatının, fonun performans değerlendirme yöntemleri değerleriyle tahmin edilmesi için geliştirilen tüm iki gizli katmanlı YSA model mimarilerinin test edilmesi sonucunda elde edilen performans ölçütlerine ilişkin ortalama, standart sapma, en büyük ve en küçük değerler Çizelge 4.58'de gösterilmiştir. Geliştirilen tüm iki gizli katmanlı YSA mimarilerinin test edilmesi sonucunda elde edilen en iyi MSE, MAPE ve R performans ölçüt değerlerinin birinci gizli katman nöron sayısı – ikinci gizli katman nöron sayısı çiftine göre değişimi ise sırasıyla Şekil 4.83, Şekil 4.84 ve Şekil 4.85'te gösterilmiştir.


**Çizelge 4.58.** DBP'nin performans değerlendirme yöntemleri değerlerinin iki gizli katmanlı YSA ile test edilmesi sonucu elde edilen kapanış fiyatı tahminine ilişkin performans ölçüt değerleri

Performans Ölçütleri		SSE	MSE	RMSE	MAE	MAPE	R	R <sup>2</sup>
BR	Ortalama	1,25E-05	7,39E-08	1,52E-04	1,10E-04	0,324405	0,999146	0,998334
	St. Sapma	9,07E-05	5,37E-07	2,25E-04	1,44E-04	0,411644	0,006358	0,012164
	En Büyük	1,82E-03	1,08E-05	3,28E-03	1,86E-03	5,317376	0,999966	0,999932
	En Küçük	5,32E-07	3,15E-09	5,61E-05	4,29E-05	0,130829	0,869106	0,755344
LM	Ortalama	4,13E-05	2,44E-07	2,04E-04	1,47E-04	0,433912	0,996672	0,994572
	St. Sapma	3,20E-04	1,89E-06	4,50E-04	3,26E-04	0,959081	0,034875	0,041757
	En Büyük	7,74E-03	4,58E-05	6,77E-03	6,02E-03	18,07980	<b>0,999970</b>	<b>0,999940</b>
	En Küçük	<b>4,70E-07</b>	<b>2,78E-09</b>	<b>5,27E-05</b>	<b>3,69E-05</b>	<b>0,108825</b>	0,007349	5,40E-05
SCG	Ortalama	1,62E-04	9,57E-07	7,02E-04	5,29E-04	1,531559	0,986683	0,978938
	St. Sapma	6,47E-04	3,83E-06	6,81E-04	5,45E-04	1,607917	0,073452	0,082167
	En Büyük	7,68E-03	4,54E-05	6,74E-03	6,02E-03	17,84064	0,999403	0,998806
	En Küçük	9,05E-06	5,35E-08	2,31E-04	1,78E-04	0,521651	-0,314410	0,005468


DBP'nin performans değerlendirme yöntemleri değerlerinin iki gizli katmanlı YSA ile test edilmesi sonucu elde edilen performans ölçütlerinin tamamı için en iyi değerlere LM eğitim algoritmasına ve 6-8-9-1 model mimarisine sahip ağda ulaşılmıştır.



**Şekil 4.83.** Performans değerlendirme yöntemleri değerleri ile DBP'nin kapanış fiyatının tahmini için geliştirilen her bir iki gizli katmanlı YSA model mimarisine için gerçekleştirilen test iterasyonları sonucunda elde edilen en iyi MSE değerleri



**Şekil 4.84.** Performans değerlendirme yöntemleri değerleri ile DBP'nin kapanış fiyatının tahmini için geliştirilen her bir iki gizli katmanlı YSA model mimarisi için gerçekleştirilen test iterasyonları sonucunda elde edilen en iyi MAPE değerleri



**Şekil 4.85.** Performans değerlendirme yöntemleri değerleri ile DBP'nin kapanış fiyatının tahmini için geliştirilen her bir iki gizli katmanlı YSA model mimarisi için gerçekleştirilen test iterasyonları sonucunda elde edilen en iyi R değerleri

6-8-9-1 model mimarisine sahip iki gizli katmanlı YSA'da eğitim algoritması çeşidine göre elde edilen eğitim, doğrulama ve test performans ölçüt sonuçları sırasıyla Çizelge 4.59, Çizelge 4.60 ve Çizelge 4.61'de gösterilmiştir.

**Çizelge 4.59.** DBP'nin performans değerlendirme yöntemleri değerlerinin iki gizli katmanlı YSA ile eğitimi sonucu elde edilen kapanış fiyatı tahminine ilişkin performans ölçüt değerleri (model: 6-8-9-1)

Performans Ölçütleri	Eğitim Algoritması		
	BR	LM	SCG
SSE	6,69E-06	2,05E-06	7.87E-05
MSE	6,98E-09	2,59E-09	9.96E-08
RMSE	8,35E-05	5,09E-05	3.16E-04
MAE	6,22E-05	3,64E-05	2.46E-04
MAPE	0,190056	0,110504	0.740367
R	0,999921	0,999970	0.998893
R <sup>2</sup>	0,999842	0,999939	0.997788


**Çizelge 4.60.** DBP'nin performans değerlendirme yöntemleri değerlerinin iki gizli katmanlı YSA ile doğrulanması sonucu elde edilen kapanış fiyatı tahminine ilişkin performans ölçüt değerleri (model: 6-8-9-1)

Performans Ölçütleri	Eğitim Algoritması		
	BR	LM	SCG
SSE	-	4,93E-07	1,59E-05
MSE	-	2,92E-09	9,42E-08
RMSE	-	5,40E-05	3,07E-04
MAE	-	3,91E-05	2,35E-04
MAPE	-	0,120513	0,709738
R	-	0,999971	0,998864
R <sup>2</sup>	-	0,999941	0,997729

**Çizelge 4.61.** DBP'nin performans değerlendirme yöntemleri değerlerinin iki gizli katmanlı YSA ile test edilmesi sonucu elde edilen kapanış fiyatı tahminine ilişkin performans ölçüt değerleri (model: 6-8-9-1)

Performans Ölçütleri	Eğitim Algoritması		
	BR	LM	SCG
SSE	1,11E-06	4,70E-07	1,89E-05
MSE	6,59E-09	2,78E-09	1,12E-07
RMSE	8,11E-05	5,27E-05	3,35E-04
MAE	5,72E-05	3,69E-05	2,60E-04
MAPE	0,171911	0,108825	0,775753
R	0,999925	0,999970	0,998694
R <sup>2</sup>	0,999850	0,999940	0,997389


İlgili model mimarisi Şekil 4.86'da gösterilmiştir.



**Şekil 4.86.** DBP'nin performans değerlendirme yöntemleri değerleri ile kapanış fiyatının tahminine ilişkin iki gizli katmanlı YSA model mimarisi (eğitim algoritması: LM, model: 6-8-9-1)


Performans ölçütlerinden MSE'nin eğitim, doğrulama ve test için performansı Şekil 4.87'de gösterilmektedir. Şekilde en iyi doğrulama performansının 2,9185E-09 MSE ile 28. eğitim turunda elde edildiği görülmektedir.






**Şekil 4.87.** Performans değerlendirme yöntemleri değerleri ile DBP'nin kapanış fiyatının tahmini için geliştirilen iki gizli katmanlı YSA'nın MSE Performansı (eğitim algoritması: LM, model: 6-8-9-1)

Şekil 4.88, DBP'nin performans değerlendirme yöntemleri değerleri ile kapanış fiyatının tahminine ilişkin iki gizli katmanlı YSA'nın eğitim durumunu özetlemektedir.




**Şekil 4.88.** Performans değerlendirme yöntemleri değerleri ile DBP'nin kapanış fiyatının tahmini için geliştirilen iki gizli katmanlı YSA'nın eğitim durumu (eğitim algoritması: LM, model: 6-8-9-1)

Eđitilmiş ađın eđitim, dođrulama ve test hatalarından oluřan bir hata histogramı Őekil 4.89’da gsterilmiřtir. Őekil incelendiđinde hataların ođunun  $\pm 0,0001$  aralıđında olduđu ve maksimum hatanın yaklařık olarak 0,0003 olduđu tespit edilebilir. Ayrıca sıfır hata noktası  $-8,20E-06$  merkezli tanımlanmıř blmenin altına dřmektedir.



**Őekil 4.89.** Performans deđerlendirme yntemleri deđerleri ile DBP’nin kapanıř fiyatının tahmini iin geliřtirilen iki gizli katmanlı YSA’nın hata histogramı (eđitim algoritması: LM, model: 6-8-9-1)

Ađın gerekleřen deđerler ile tahmin edilen deđerler arasındaki regresyon grafiđi Őekil 4.90’da gsterilmiřtir. Őekilde YSA modelinin eđitimi, dođrulaması ve testi iin tm korelasyon katsayısı deđerlerine yer verilmiřtir. Eđitim, dođrulama ve test iin korelasyon katsayısı deđerleri sırasıyla 0,99997, 0,99997 ve 0,99997’dir. Ayrıca tm veriler iin elde edilen korelasyon katsayısı deđerinin 0,99997 olması, elde edilen tahmin modelinin ıktılarının gerekleřen ıktı deđerleriyle uyum iinde olduđu ve bu deđerler arasında sapma olmadıđı anlamına gelmektedir.



**Şekil 4.90.** Performans değerlendirme yöntemleri değerleri ile DBP'nin kapanış fiyatının tahmini için geliştirilen iki gizli katmanlı YSA'nın regresyon grafikleri (eğitim algoritması: LM, model: 6-8-9-1)

#### 4.2.1.2.2. En çok işlem gören yatırım fonuna ilişkin bulgular

IST'nin kapanış fiyatının, fonun performans değerlendirme yöntemleri değerleriyle tahmin edilmesi için geliştirilen tüm iki gizli katmanlı YSA model mimarilerinin eğitimi sonucunda elde edilen performans ölçütlerine ilişkin ortalama, standart sapma, en büyük ve en küçük değerler Çizelge 4.62'de gösterilmiştir.

**Çizelge 4.62.** IST'nin performans değerlendirme yöntemleri değerlerinin iki gizli katmanlı YSA ile eğitimi sonucu elde edilen kapanış fiyatı tahminine ilişkin performans ölçüt değerleri

Performans Ölçütleri		SSE	MSE	RMSE	MAE	MAPE	R	R <sup>2</sup>
BR	Ortalama	2,17E-04	2,26E-07	2,64E-04	1,96E-04	0,822695	0,995357	0,991718
	St. Sapma	1,00E-03	1,04E-06	3,95E-04	2,97E-04	1,276860	0,031359	0,038253
	En Büyük	2,60E-02	2,71E-05	5,21E-03	4,68E-03	19,54844	0,999942	0,999885
	En Küçük	3,05E-06	3,18E-09	5,64E-05	3,89E-05	0,157229	0,071904	0,005170
LM	Ortalama	2,11E-04	2,67E-07	2,91E-04	2,11E-04	0,877881	0,994982	0,990241
	St. Sapma	6,57E-04	8,32E-07	4,27E-04	2,93E-04	1,244299	0,015843	0,030398
	En Büyük	5,48E-03	6,93E-06	2,63E-03	1,75E-03	7,406439	<b>0,999960</b>	<b>0,999920</b>
	En Küçük	<b>1,73E-06</b>	<b>2,19E-09</b>	<b>4,68E-05</b>	<b>3,28E-05</b>	<b>0,137357</b>	0,868520	0,754327
SCG	Ortalama	9,16E-04	1,16E-06	8,37E-04	6,47E-04	2,716529	0,972792	0,959456
	St. Sapma	2,44E-03	3,08E-06	6,78E-04	5,67E-04	2,419423	0,114594	0,099369
	En Büyük	2,21E-02	2,80E-05	5,29E-03	4,77E-03	19,99337	0,998466	0,996934
	En Küçük	6,63E-05	8,40E-08	2,90E-04	2,11E-04	0,844217	-0,696520	0,000294

IST'nin performans değerlendirme yöntemleri değerlerinin iki gizli katmanlı YSA ile eğitimi sonucu elde edilen performans ölçütlerinin tamamı için en iyi değerlere LM eğitim algoritmasına ve 6-10-8-1 model mimarisine sahip ağda ulaşılmıştır.

IST'nin kapanış fiyatının, fonun performans değerlendirme yöntemleri değerleriyle tahmin edilmesi için geliştirilen tüm iki gizli katmanlı YSA model mimarilerinin doğrulanması sonucunda elde edilen performans ölçütlerine ilişkin ortalama, standart sapma, en büyük ve en küçük değerler Çizelge 4.63'te gösterilmiştir.

**Çizelge 4.63.** IST'nin performans değerlendirme yöntemleri değerlerinin iki gizli katmanlı YSA ile doğrulanması sonucu elde edilen kapanış fiyatı tahminine ilişkin performans ölçüt değerleri

Performans Ölçütleri		SSE	MSE	RMSE	MAE	MAPE	R	R <sup>2</sup>
BR	Ortalama	-	-	-	-	-	-	-
	St. Sapma	-	-	-	-	-	-	-
	En Büyük	-	-	-	-	-	-	-
	En Küçük	-	-	-	-	-	-	-
LM	Ortalama	4,68E-05	2,77E-07	2,99E-04	2,17E-04	0,901905	0,994816	0,989947
	St. Sapma	1,51E-04	8,91E-07	4,33E-04	2,98E-04	1,261820	0,016989	0,032304
	En Büyük	1,55E-03	9,15E-06	3,02E-03	1,87E-03	7,586926	<b>0,999957</b>	<b>0,999914</b>
	En Küçük	<b>4,20E-07</b>	<b>2,49E-09</b>	<b>4,99E-05</b>	<b>3,46E-05</b>	<b>0,139596</b>	0,829246	0,687649
SCG	Ortalama	1,98E-04	1,17E-06	8,40E-04	6,52E-04	2,729581	0,972851	0,959697
	St. Sapma	5,35E-04	3,17E-06	6,80E-04	5,73E-04	2,423157	0,115142	0,098230
	En Büyük	5,17E-03	3,06E-05	5,53E-03	5,10E-03	21,01041	0,998759	0,997520
	En Küçük	1,16E-05	6,88E-08	2,62E-04	1,93E-04	0,767920	-0,717170	1,23E-07


IST'nin performans değerlendirme yöntemleri değerlerinin iki gizli katmanlı YSA ile doğrulanması sonucu elde edilen performans ölçütlerinin tamamı için en iyi değerlere LM eğitim algoritmasına ve 6-10-8-1 model mimarisine sahip ağda ulaşılmıştır.

IST'nin kapanış fiyatının, fonun performans değerlendirme yöntemleri değerleriyle tahmin edilmesi için geliştirilen tüm iki gizli katmanlı YSA model mimarilerinin test edilmesi sonucunda elde edilen performans ölçütlerine ilişkin ortalama, standart sapma, en büyük ve en küçük değerler Çizelge 4.64'te gösterilmiştir. Geliştirilen tüm iki gizli katmanlı YSA mimarilerinin test edilmesi sonucunda elde edilen en iyi MSE, MAPE ve R performans ölçüt değerlerinin birinci gizli katman nöron sayısı – ikinci gizli katman nöron sayısı çiftine göre değişimi ise sırasıyla Şekil 4.91, Şekil 4.92 ve Şekil 4.93'te gösterilmiştir.


**Çizelge 4.64.** IST'nin performans değerlendirme yöntemleri değerlerinin iki gizli katmanlı YSA ile test edilmesi sonucu elde edilen kapanış fiyatı tahminine ilişkin performans ölçüt değerleri

Performans Ölçütleri		SSE	MSE	RMSE	MAE	MAPE	R	R <sup>2</sup>
BR	Ortalama	4,01E-05	2,37E-07	2,73E-04	2,01E-04	0,841130	0,995172	0,991396
	St. Sapma	1,87E-04	1,11E-06	4,04E-04	3,02E-04	1,298431	0,032071	0,039566
	En Büyük	4,76E-03	2,82E-05	5,31E-03	4,86E-03	20,66599	0,999940	0,999880
	En Küçük	6,07E-07	3,59E-09	5,99E-05	4,50E-05	0,183567	0,063800	0,004070
LM	Ortalama	5,00E-05	2,96E-07	3,05E-04	2,20E-04	0,911872	0,994401	0,989200
	St. Sapma	1,66E-04	9,82E-07	4,50E-04	3,07E-04	1,297007	0,019125	0,035852
	En Büyük	2,15E-03	1,27E-05	3,57E-03	2,12E-03	8,306502	<b>0,999962</b>	<b>0,999924</b>
	En Küçük	<b>3,91E-07</b>	<b>2,32E-09</b>	<b>4,81E-05</b>	<b>3,52E-05</b>	<b>0,141640</b>	0,735736	0,541308
SCG	Ortalama	2,06E-04	1,22E-06	8,54E-04	6,60E-04	2,762365	0,972069	0,958155
	St. Sapma	5,46E-04	3,23E-06	6,98E-04	5,81E-04	2,457653	0,115057	0,100038
	En Büyük	5,13E-03	3,04E-05	5,51E-03	5,03E-03	21,19493	0,998384	0,996770
	En Küçük	1,50E-05	8,87E-08	2,98E-04	2,02E-04	0,801414	-0,705150	1,88E-06


IST'nin performans değerlendirme yöntemleri değerlerinin iki gizli katmanlı YSA ile test edilmesi sonucu elde edilen performans ölçütlerinin tamamı için en iyi değerlere LM eğitim algoritmasına ve 6-9-9-1 model mimarisine sahip ağda ulaşılmıştır.



**Şekil 4.91.** Performans değerlendirme yöntemleri değerleri ile IST'nin kapanış fiyatının tahmini için geliştirilen her bir iki gizli katmanlı YSA model mimarisini için gerçekleştirilen test iterasyonları sonucunda elde edilen en iyi MSE değerleri



**Şekil 4.92.** Performans değerlendirme yöntemleri değerleri ile IST'nin kapanış fiyatının tahmini için geliştirilen her bir iki gizli katmanlı YSA model mimarisi için gerçekleştirilen test iterasyonları sonucunda elde edilen en iyi MAPE değerleri



**Şekil 4.93.** Performans değerlendirme yöntemleri değerleri ile IST'nin kapanış fiyatının tahmini için geliştirilen her bir iki gizli katmanlı YSA model mimarisi için gerçekleştirilen test iterasyonları sonucunda elde edilen en iyi R değerleri

6-9-9-1 model mimarisine sahip YSA’da eğitim algoritması çeşidine göre elde edilen eğitim, doğrulama ve test performans ölçüt sonuçları sırasıyla Çizelge 4.65, Çizelge 4.66 ve Çizelge 4.67’de gösterilmiştir.

**Çizelge 4.65.** IST’nin performans değerlendirme yöntemleri değerlerinin iki gizli katmanlı YSA ile eğitimi sonucu elde edilen kapanış fiyatı tahminine ilişkin performans ölçüt değerleri (model: 6-9-9-1)

Performans Ölçütleri	Eğitim Algoritması		
	BR	LM	SCG
SSE	4,12E-06	2,42E-06	8,42E-05
MSE	4,30E-09	3,06E-09	1,07E-07
RMSE	6,56E-05	5,54E-05	3,27E-04
MAE	4,73E-05	3,61E-05	2,44E-04
MAPE	0,198952	0,146946	0,955300
R	0,999920	0,999943	0,998051
R <sup>2</sup>	0,999840	0,999886	0,996106

**Çizelge 4.66.** IST’nin performans değerlendirme yöntemleri değerlerinin iki gizli katmanlı YSA ile doğrulanması sonucu elde edilen kapanış fiyatı tahminine ilişkin performans ölçüt değerleri (model: 6-9-9-1)


Performans Ölçütleri	Eğitim Algoritması		
	BR	LM	SCG
SSE	-	4,95E-07	1,86E-05
MSE	-	2,93E-09	1,10E-07
RMSE	-	5,41E-05	3,31E-04
MAE	-	3,70E-05	2,59E-04
MAPE	-	0,154140	1,009613
R	-	0,999945	0,998148
R <sup>2</sup>	-	0,999890	0,996300



**Çizelge 4.67.** IST'nin performans değerlendirme yöntemleri değerlerinin iki gizli katmanlı YSA ile test edilmesi sonucu elde edilen kapanış fiyatı tahminine ilişkin performans ölçüt değerleri (model: 6-9-9-1)


Performans Ölçütleri	Eğitim Algoritması		
	BR	LM	SCG
SSE	8,23E-07	3,91E-07	2,24E-05
MSE	4,87E-09	2,32E-09	1,33E-07
RMSE	6,98E-05	4,81E-05	3,64E-04
MAE	5,14E-05	3,52E-05	2,57E-04
MAPE	0,211311	0,141640	0,983022
R	0,999920	0,999962	0,997379
R <sup>2</sup>	0,999840	0,999924	0,994764

İlgili model mimarisi Şekil 4.94'te gösterilmiştir.




**Şekil 4.94.** Performans değerlendirme yöntemleri değerleri ile IST'nin kapanış fiyatının tahmini için geliştirilen iki gizli katmanlı YSA model mimarisi (eğitim algoritması: LM, model: 6-9-9-1)

Performans ölçütlerinden MSE'nin eğitim, doğrulama ve test için performansı Şekil 4.95'te gösterilmektedir. Şekilden en iyi doğrulama performansının 2,9281E-09 MSE ile 25. eğitim turunda elde edildiği sonucu çıkarılabilir.




**Şekil 4.95.** Performans değerlendirme yöntemleri değerleri ile IST'nin kapanış fiyatının tahmini için geliştirilen iki gizli katmanlı YSA'nın MSE performansı (eğitim algoritması: LM, model: 6-9-9-1)

Şekil 4.96, IST'nin performans değerlendirme yöntemleri değerleri ile kapanış fiyatının tahminine ilişkin iki gizli katmanlı YSA'nın eğitim durumunu özetlemektedir.




**Şekil 4.96.** Performans değerlendirme yöntemleri değerleri ile IST'nin kapanış fiyatının tahmini için geliştirilen iki gizli katmanlı YSA'nın eğitim durumu (eğitim algoritması: LM, model: 6-9-9-1)

Eđitilmiş ađın eđitim, dođrulama ve test hatalarından oluřan bir hata histogramı Őekil 4.97’de gsterilmiřtir. Őekilde gsterilen hata histogramı, elde edilen veri uydurma hatalarının normal olarak yaklařık sıfır hata (hedef-ıktı) gibi iyi bir aralıktadađıtıldıđını gstermektedir. Őekil incelendiđinde hataların ođunun  $\pm 8E-05$  aralıđında olduđu ve maksimum hatanın yaklařık olarak 0,0007 olduđu tespit edilebilir. Ayrıca sıfır hata noktası  $-1,2E-05$  merkezli tanımlanmış blmenin altına dřmektedir.



**Őekil 4.97.** Performans deđerlendirme yntemleri deđerleri ile IST’nin kapanıř fiyatının tahminine iliřkin iki gizli katmanlı YSA’nın hata histogramı (eđitim algoritması: LM, model: 6-9-9-1)

Ađın gerekleřen deđerler ile tahmin edilen deđerler arasındaki regresyon grafiđi Őekil 4.98’de gsterilmiřtir. Őekilde grldđ gibi iki gizli katmanlı YSA modelinin eđitim, dođrulama ve test korelasyon katsayısı deđerleri sırasıyla 0,99994, 0,99995 ve 0,99996 olarak bulunmuřtur. Ayrıca tm veriler iin elde edilen korelasyon katsayısı deđerinin 0,99995 olması, elde edilen tahmin modelinin ıktılarının gerekleřen ıktı deđerleriyle uyum iinde olduđu ve bu deđerler arasında sapma olmadıđı anlamına gelmektedir.



**Şekil 4.98.** Performans değerlendirme yöntemleri değerleri ile IST'nin kapanış fiyatının tahminine ilişkin iki gizli katmanlı YSA'nın regresyon grafikleri (eğitim algoritması: LM, model: 6-9-9-1)

#### 4.2.2. Yatırım fonu kapanış fiyatının performans değerlendirme yöntemleri değerlerinden faydalanılarak tahmin edilmesi için NARX model mimarilerinin geliştirilmesi

Çalışmada NARX ağlarını eğitmek için LM, BR ve SCG eğitim algoritmalarından faydalanılmıştır. Yatırım fonu kapanış fiyatının performans değerlendirme yöntemleri değerlerinden faydalanılarak tahmin edilmesi için geliştirilen NARX model mimarisine örnek olarak 6-(2)-3-1 gösterimi verilebilir. Gösterimde 6 sayısı girdi sayısını, 2 sayısı

gecikme sayısını, 3 sayısı gizli katman nöron sayısını ve 1 sayısı çıktı sayısını temsil etmektedir.

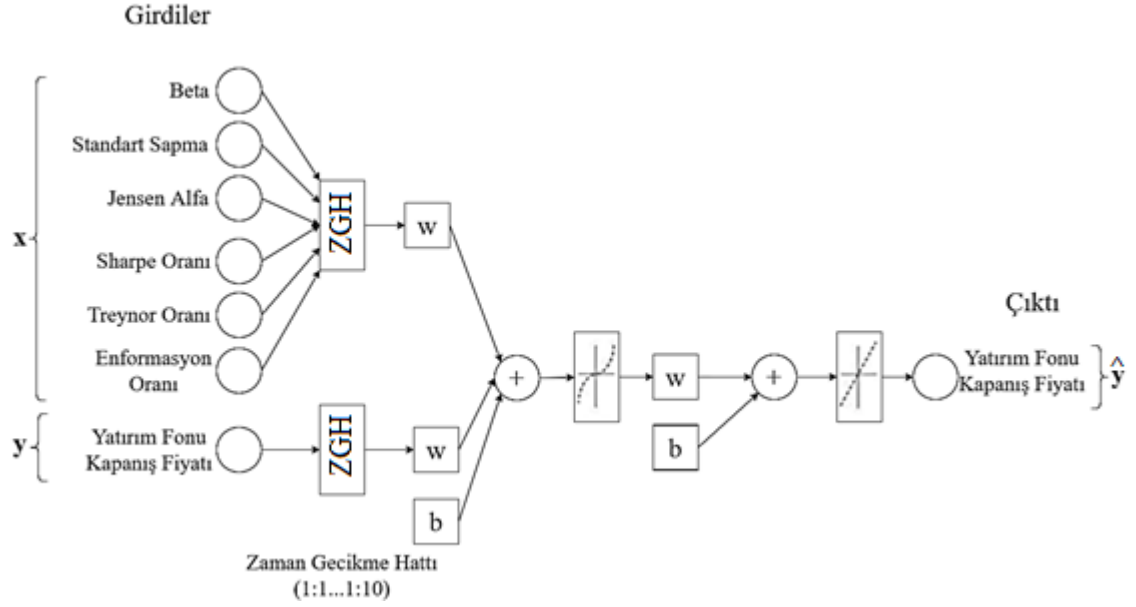
Dinamik sinir ağı doğrusal olmayan bir zaman serisi probleminin çözümünde kullanılan ağ modelinin yapısı girdi sayısı, çıktı sayısı, girdi katmanı – gizli katman – çıktı katmanı arasındaki aktivasyon fonksiyonları, verinin eğitim – doğrulama – test dağılımı oranı, döngü sayısı ve hata hedefi gibi parametreleri içermektedir. Önerilen ağ modelinin tasarımında kullanılan parametreler, analizde faydalanan eğitim algoritmalarına göre Çizelge 4.68’de gösterildiği gibi sınıflandırılmıştır.

**Çizelge 4.68.** NARX algoritmasının tasarım parametreleri

Ağ parametreleri		Eğitim algoritmaları		
		LM	BR	SCG
Girdi sayısı		6	6	6
Çıktı sayısı		1	1	1
Aktivasyon fonksiyonu	Girdi-Gizli	Hiperbolik tanjant sigmoid	Hiperbolik tanjant sigmoid	Hiperbolik tanjant sigmoid
	Gizli-Çıktı	Lineer	Lineer	Lineer
Veri bölme	Eğitim	%70	%85	%70
	Doğrulama	%15	-	%15
	Test	%15	%15	%15
Eğitim tur sayısı		1000	1000	1000
Performans hedefi		0	0	0
Başlangıç mu değeri		0,005	0,001	-
mu için indirgeme faktörü		0,1	0,1	-
mu için çoğaltma faktörü		10	10	-
mu için maksimum değer		1e10	1e10	-
Maksimum doğrulama hatası		0	6	6
Minimum performans gradyanı		1e-7	1e-7	1e-6
Sigma		-	-	5e-5
Lambda		-	-	5e-7

İlgili menkul kıymet yatırım fonlarının günlük kapanış fiyatının tahminini yapmak amacıyla girdi olarak Beta, Standart sapma, Jensen alfa, Sharpe oranı, Treynor oranı ve Enformasyon oranı olmak üzere 6 tane risk ve performans ölçütünden faydalanılmıştır.

Çıktı ise ilgili fonların günlük kapanış fiyatlarıdır. Yatırım fonlarının kapanış fiyatının performans değerlendirme yöntemleri değerlerinden faydalanılarak tahmin edilmesi için geliştirilen NARX sinir ağı mimarisi Şekil 4.99'da gösterilmiştir.



**Şekil 4.99.** Yatırım fonu kapanış fiyatının performans değerlendirme yöntemleri değerlerinden faydalanılarak tahmin edilmesi için geliştirilen NARX sinir ağı model mimarisi

NARX modelinin çözümünde üç farklı eğitim algoritması kullanılarak, gizli katman büyüklüğü 1 ile 10 arasında değiştirilerek ve gecikme sayısı 1 ile 10 arasında değiştirilerek, her bir fon için toplam 300 farklı ağ yapısı oluşturulmuştur. Bu 300 farklı ağ yapısı için analiz 10 kez tekrarlanmış ve her bir fon için 3000 olmak üzere toplam 6000 analiz gerçekleştirilmiştir.

NARX modelini eğittikten sonra, modelin tahmininin doğruluğunu değerlendirmek için SSE, MSE, RMSE, MAE, MAPE, R ve  $R^2$  performans ölçütlerinden faydalanılmıştır.

#### 4.2.2.1. En fazla sayıda portföye dağılan yatırım fonuna ilişkin bulgular

DBP'nin kapanış fiyatının, fonun performans değerlendirme yöntemleri değerleriyle tahmin edilmesi için geliştirilen tüm NARX model mimarilerinin eğitimi sonucunda elde

edilen performans ölçütlerine ilişkin ortalama, standart sapma, en büyük ve en küçük değerler Çizelge 4.69’da gösterilmiştir.

**Çizelge 4.69.** DBP’nin performans değerlendirme yöntemleri değerlerinin NARX ile eğitimi sonucu elde edilen kapanış fiyatı tahminine ilişkin performans ölçüt değerleri

Performans Ölçütleri		SSE	MSE	RMSE	MAE	MAPE	R	R <sup>2</sup>
BR	Ortalama	4,48E-06	4,69E-09	6,75E-05	4,54E-05	0,128225	0,999947	0,999893
	St. Sapma	1,76E-06	1,85E-09	1,17E-05	9,89E-06	0,030331	2,10E-05	4,21E-05
	En Büyük	1,51E-05	1,58E-08	1,26E-04	9,34E-05	0,277712	0,999972	0,999944
	En Küçük	2,37E-06	2,49E-09	4,99E-05	3,30E-05	0,091560	0,999820	0,999641
LM	Ortalama	3,42E-06	4,35E-09	6,40E-05	4,41E-05	0,124724	0,999951	0,999901
	St. Sapma	2,00E-06	2,54E-09	1,57E-05	1,24E-05	0,036797	2,88E-05	5,75E-05
	En Büyük	2,05E-05	2,60E-08	1,61E-04	1,21E-04	0,354551	<b>0,999982</b>	<b>0,999963</b>
	En Küçük	<b>1,25E-06</b>	<b>1,60E-09</b>	<b>3,99E-05</b>	<b>2,74E-05</b>	<b>0,077801</b>	0,999705	0,999411
SCG	Ortalama	1,14E-04	1,45E-07	3,61E-04	2,68E-04	0,762868	0,998350	0,996713
	St. Sapma	2,07E-04	2,64E-07	1,22E-04	9,97E-05	0,296973	0,003111	0,005944
	En Büyük	6,35E-03	8,11E-06	2,85E-03	2,40E-03	7,053026	0,999629	0,999259
	En Küçük	2,71E-05	3,43E-08	1,85E-04	1,38E-04	0,396782	0,904272	0,817708

DBP’nin performans değerlendirme yöntemleri değerlerinin NARX ile eğitimi sonucu elde edilen performans ölçütlerinden SSE, MSE, RMSE, R ve R<sup>2</sup> için en iyi değerlere LM eğitim algoritmasına ve 6-(7)-10-1 model mimarisine sahip ağda ulaşılmıştır. En iyi MAE ve MAPE değerlerine ise LM eğitim algoritmasına ve 6-(10)-7-1 model mimarisine sahip ağda ulaşılmıştır.

DBP’nin kapanış fiyatının, fonun performans değerlendirme yöntemleri değerleriyle tahmin edilmesi için geliştirilen tüm NARX model mimarilerinin doğrulanması sonucunda elde edilen performans ölçütlerine ilişkin ortalama, standart sapma, en büyük ve en küçük değerler Çizelge 4.70’te gösterilmiştir.

**Çizelge 4.70.** DBP'nin performans değerlendirme yöntemleri değerlerinin NARX ile doğrulanması sonucu elde edilen kapanış fiyatı tahminine ilişkin performans ölçüt değerleri

Performans Ölçütleri		SSE	MSE	RMSE	MAE	MAPE	R	R <sup>2</sup>
BR	Ortalama	-	-	-	-	-	-	-
	St. Sapma	-	-	-	-	-	-	-
	En Büyük	-	-	-	-	-	-	-
	En Küçük	-	-	-	-	-	-	-
LM	Ortalama	9,40E-07	5,58E-09	7,28E-05	4,87E-05	0,136967	0,999937	0,999874
	St. Sapma	4,95E-07	2,94E-09	1,69E-05	1,25E-05	0,037027	3,33E-05	6,65E-05
	En Büyük	4,98E-06	2,95E-08	1,72E-04	1,30E-04	0,391519	<b>0,999981</b>	<b>0,999961</b>
	En Küçük	<b>2,83E-07</b>	<b>1,68E-09</b>	<b>4,10E-05</b>	<b>2,95E-05</b>	<b>0,084392</b>	0,999682	0,999364
SCG	Ortalama	2,50E-05	1,49E-07	3,64E-04	2,70E-04	0,768646	0,998327	0,996668
	St. Sapma	4,87E-05	2,90E-07	1,27E-04	1,04E-04	0,309974	0,003370	0,006409
	En Büyük	1,50E-03	8,93E-06	2,99E-03	2,55E-03	7,562001	0,999657	0,999315
	En Küçük	4,58E-06	2,71E-08	1,65E-04	1,29E-04	0,361631	0,895810	0,802476

DBP'nin performans değerlendirme yöntemleri değerlerinin NARX ile doğrulanması sonucu elde edilen performans ölçütlerinden SSE, MSE, RMSE, MAE, R ve R<sup>2</sup> için en iyi değerlere LM eğitim algoritmasına ve 6-(9)-2-1 model mimarisine sahip ağda ulaşılmıştır. En iyi MAPE değerine ise LM eğitim algoritmasına ve 6-(2)-2-1 model mimarisine sahip ağda ulaşılmıştır.


DBP'nin kapanış fiyatının, fonun performans değerlendirme yöntemleri değerleriyle tahmin edilmesi için geliştirilen tüm NARX model mimarilerinin test edilmesi sonucunda elde edilen performans ölçütlerine ilişkin ortalama, standart sapma, en büyük ve en küçük değerler Çizelge 4.71'de gösterilmiştir. Geliştirilen tüm NARX mimarilerinin test edilmesi sonucunda elde edilen en iyi MSE, MAPE ve R performans ölçüt değerlerinin gecikme sayısı - gizli katman nöron sayısı çiftine göre değişimi ise sırasıyla Şekil 4.100, Şekil 4.101 ve Şekil 4.102'de gösterilmiştir.




**Çizelge 4.71.** DBP'nin performans değerlendirme yöntemleri değerlerinin NARX ile test edilmesi sonucu elde edilen kapanış fiyatı tahminine ilişkin performans ölçüt değerleri

Performans Ölçütleri		SSE	MSE	RMSE	MAE	MAPE	R	R <sup>2</sup>
BR	Ortalama	8,88E-07	5,28E-09	7,11E-05	4,75E-05	0,133859	0,999941	0,999881
	St. Sapma	4,06E-07	2,42E-09	1,48E-05	1,08E-05	0,032845	2,77E-05	5,54E-05
	En Büyük	3,37E-06	1,99E-08	1,41E-04	1,10E-04	0,322926	<b>0,999981</b>	<b>0,999961</b>
	En Küçük	<b>2,89E-07</b>	<b>1,71E-09</b>	<b>4,13E-05</b>	<b>2,92E-05</b>	0,083210	0,999770	0,999541
LM	Ortalama	9,65E-07	5,73E-09	7,37E-05	4,93E-05	0,138211	0,999936	0,999871
	St. Sapma	5,08E-07	3,01E-09	1,72E-05	1,26E-05	0,036992	3,41E-05	6,81E-05
	En Büyük	4,94E-06	2,92E-08	1,71E-04	1,19E-04	0,347110	0,999978	0,999956
	En Küçük	3,19E-07	1,90E-09	4,36E-05	2,97E-05	<b>0,082985</b>	0,999688	0,999375
SCG	Ortalama	2,53E-05	1,50E-07	3,65E-04	2,71E-04	0,773573	0,998303	0,996622
	St. Sapma	4,84E-05	2,88E-07	1,28E-04	1,04E-04	0,313889	0,003645	0,006898
	En Büyük	1,49E-03	8,86E-06	2,98E-03	2,52E-03	7,568520	0,999625	0,999251
	En Küçük	5,28E-06	3,12E-08	1,77E-04	1,32E-04	0,379103	0,886942	0,786667

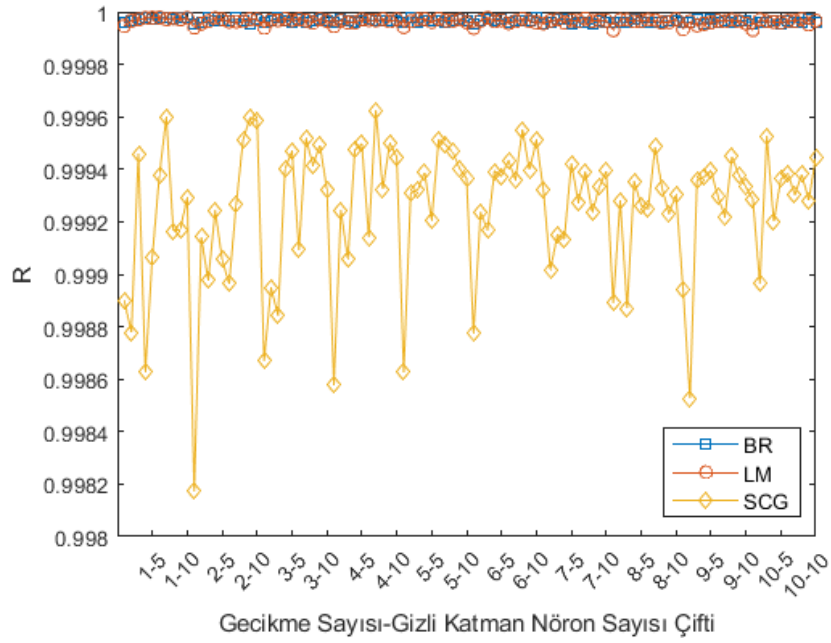
DBP'nin performans değerlendirme yöntemleri değerlerinin NARX ile test edilmesi sonucu elde edilen performans ölçütlerinden SSE, MSE ve RMSE için en iyi değerlere BR eğitim algoritmasına ve 6-(1)-9-1 model mimarisine sahip ağda ulaşılmıştır. En iyi MAE değerine BR eğitim algoritmasına ve 6-(1)-6-1 model mimarisine sahip ağda ulaşılmıştır. En iyi MAPE değerine LM eğitim algoritmasına ve 6-(1)-10-1 model mimarisine sahip ağda ulaşılmıştır. Son olarak en iyi R ve R<sup>2</sup> değerlerine BR eğitim algoritmasına ve 6-(6)-10-1 model mimarisine sahip ağda ulaşılmıştır. Performans ölçüt değerleri incelendiğinde genel olarak en iyi performans ölçütü değerlerine BR eğitim algoritmasına ve 6-(1)-9-1 model mimarisine sahip ağda ulaşılmıştır.



**Şekil 4.100.** Performans değerlendirme yöntemleri değerleri ile DBP'nin kapanış fiyatının tahmini için geliştirilen her bir NARX model mimarisi için gerçekleştirilen test iterasyonları sonucunda elde edilen en iyi MSE değerleri



**Şekil 4.101.** Performans değerlendirme yöntemleri değerleri ile DBP'nin kapanış fiyatının tahmini için geliştirilen her bir NARX model mimarisi için gerçekleştirilen test iterasyonları sonucunda elde edilen en iyi MAPE değerleri



**Şekil 4.102.** Performans değerlendirme yöntemleri değerleri ile DBP'nin kapanış fiyatının tahmini için geliştirilen her bir NARX model mimarisi için gerçekleştirilen test iterasyonları sonucunda elde edilen en iyi R değerleri

6-(1)-9-1 model mimarisine sahip NARX ağında eğitim algoritması çeşidine göre elde edilen eğitim, doğrulama ve test performans ölçüt sonuçları sırasıyla Çizelge 4.72, Çizelge 4.73 ve Çizelge 4.74'te gösterilmiştir.

**Çizelge 4.72.** DBP'nin performans değerlendirme yöntemleri değerlerinin NARX ile eğitimi sonucu elde edilen kapanış fiyatı tahminine ilişkin performans ölçüt değerleri (model: 6-(1)-9-1)

Performans Ölçütleri	Eğitim Algoritması		
	BR	LM	SCG
SSE	3,68E-06	2,85E-06	3,93E-05
MSE	3,84E-09	3,62E-09	4,98E-08
RMSE	6,20E-05	6,01E-05	2,23E-04
MAE	3,79E-05	3,63E-05	1,69E-04
MAPE	0,105163	0,100797	0,494810
R	0,999957	0,999959	0,999459
R <sup>2</sup>	0,999913	0,999918	0,998918


**Çizelge 4.73.** DBP'nin performans değerlendirme yöntemleri değerlerinin NARX ile doğrulanması sonucu elde edilen kapanış fiyatı tahminine ilişkin performans ölçüt değerleri (model: 6-(1)-9-1)

Performans Ölçütleri	Eğitim Algoritması		
	BR	LM	SCG
SSE	-	5,31E-07	9,35E-06
MSE	-	3,14E-09	5,53E-08
RMSE	-	5,60E-05	2,35E-04
MAE	-	3,61E-05	1,77E-04
MAPE	-	0,101615	0,516985
R	-	0,999960	0,999338
R <sup>2</sup>	-	0,999921	0,998677

**Çizelge 4.74.** DBP'nin performans değerlendirme yöntemleri değerlerinin NARX ile test edilmesi sonucu elde edilen kapanış fiyatı tahminine ilişkin performans ölçüt değerleri (model: 6-(1)-9-1)


Performans Ölçütleri	Eğitim Algoritması		
	BR	LM	SCG
SSE	2,89E-07	4,66E-07	1,22E-05
MSE	1,71E-09	2,76E-09	7,20E-08
RMSE	4,13E-05	5,25E-05	2,68E-04
MAE	2,96E-05	3,33E-05	2,06E-04
MAPE	0,083210	0,092783	0,591804
R	0,999980	0,999971	0,999171
R <sup>2</sup>	0,999961	0,999942	0,998342

Bahsi geçen model mimarisi Şekil 4.103'te gösterilmiştir.




**Şekil 4.103.** Performans değerlendirme yöntemleri değerleri ile DBP'nin kapanış fiyatının tahmini için geliştirilen NARX model mimarisi (eğitim algoritması: BR, model: 6-(1)-9-1)

Performans ölçütlerinden MSE'nin eğitim ve test için performansı Şekil 4.104'te gösterilmektedir. Şekilden en iyi eğitim performansının  $3,8444E-09$  MSE ile 20. eğitim turunda elde edildiği sonucu çıkarılabilir.




**Şekil 4.104.** Performans değerlendirme yöntemleri değerleri ile DBP'nin kapanış fiyatının tahmini için geliştirilen NARX'in MSE performansı (eğitim algoritması: BR, model: 6-(1)-9-1)

Şekil 4.105, performans değerlendirme yöntemleri değerleri ile DBP'nin kapanış fiyatının tahminine ilişkin NARX'in eğitim durumunu özetlemektedir.




**Şekil 4.105.** Performans değerlendirme yöntemleri değerleri ile DBP'nin kapanış fiyatının tahmini için geliştirilen NARX'in eğitim durumu (eğitim algoritması: BR, model: 6-(1)-9-1)

Eğitilmiş ağı eğitim ve test hatalarından oluşan bir hata histogramı Şekil 4.106'da gösterilmiştir. Şekilde gösterilen hata histogramı, elde edilen veri uydurma hatalarının normal olarak yaklaşık sıfır hata (hedef-çıktı) gibi iyi bir aralıkta dağıtıldığını göstermektedir. Şekil incelendiğinde hataların çoğunun  $\pm 8E-05$  aralığında olduğu ve maksimum hatanın yaklaşık olarak 0,0006 olduğu tespit edilebilir. Ayrıca sıfır hata noktası  $-1,3E-05$  merkezli tanımlanmış bölmenin altına düşmektedir. Bu nedenle, elde edilen hataya bağlı olarak, eğitilmiş ağ, kapanış fiyatının tahmini için kullanılabilir.



**Şekil 4.106.** Performans değerlendirme yöntemleri değerleri ile DBP'nin kapanış fiyatının tahmini için geliştirilen NARX'in hata histogramı (eğitim algoritması: BR, model: 6-(1)-9-1)


Ağın gerçekleşen değerler ile tahmin edilen değerler arasındaki regresyon grafiği Şekil 4.107'de gösterilmiştir. Şekilde görüldüğü üzere NARX modelinin eğitim ve test için korelasyon katsayısı değerleri sırasıyla 0,99996 ve 0,99998'dir. Ayrıca tüm veriler için elde edilen korelasyon katsayısı değerinin 0,99996 olması, elde edilen tahmin modelinin çıktılarının gerçekleşen çıktı değerleriyle uyum içinde olduğu ve bu değerler arasında sapma olmadığı anlamına gelmektedir.



**Şekil 4.107.** Performans değerlendirme yöntemleri değerleri ile DBP'nin kapanış fiyatının tahmini için geliştirilen NARX'in regresyon grafikleri (eğitim algoritması: BR, model: 6-(1)-9-1)


Şekil 4.108, eğitilmiş çıktı değeri ile hedef (gerçekleşen) değerini karşılaştırmasını göstermektedir.






**Şekil 4.108.** Performans değerlendirme yöntemleri değerleri ile DBP'nin kapanış fiyatının tahmini için geliştirilen NARX'in tahmin sonuçları (eğitim algoritması: BR, model: 6-(1)-9-1)

Uygulama performansını doğrulamak amacıyla tahmin prosedürü ile elde edilen otokorelasyonlar Şekil 4.109'da gösterilmiştir. Şekilde, sıfır gecikmeli korelasyon dışındaki korelasyonlar, %95 güven sınırları içinde kalmamasına rağmen sıfır etrafında dalgalanmaktadır. Bu nedenle model yeterli görülmektedir.



**Şekil 4.109.** Performans değerlendirme yöntemleri değerleri ile DBP'nin kapanış fiyatının tahmini için geliştirilen NARX'in hata otokorelasyonları (eğitim algoritması: BR, model: 6-(1)-9-1)

Şekil 4.110'da gösterilen girdi-hata çapraz korelasyon fonksiyonu, hataların girdi dizisi ile nasıl ilişkilendirildiğini göstermektedir. Mükemmel bir tahmin modeli için tüm korelasyonlar sıfır olmalıdır. Şekil, girdi çıktı hatası çapraz korelasyonununun %95 güven sınırı içinde olduğunu göstermektedir ve tüm korelasyonlar neredeyse sıfıra yakındır. Bu da yeterli bir tahmin modelinin olduğunu göstermektedir (Matzenberger, 2013).



**Şekil 4.110.** Performans değerlendirme yöntemleri değerleri ile DBP'nin kapanış fiyatının tahmini için geliştirilen NARX'in girdi-hata çapraz-korelasyonları (eğitim algoritması: BR, model: 6-(1)-9-1)

#### 4.2.2.2. En çok işlem gören yatırım fonuna ilişkin bulgular

IST'nin kapanış fiyatının, fonun performans değerlendirme yöntemleri değerleriyle tahmin edilmesi için geliştirilen tüm NARX model mimarilerinin eğitimi sonucunda elde edilen performans ölçütlerine ilişkin ortalama, standart sapma, en büyük ve en küçük değerler Çizelge 4.75'te gösterilmiştir.

**Çizelge 4.75.** IST'nin performans değerlendirme yöntemleri değerlerinin NARX ile eğitimi sonucu elde edilen kapanış fiyatı tahminine ilişkin performans ölçüt değerleri

Performans Ölçütleri	SSE	MSE	RMSE	MAE	MAPE	R	R <sup>2</sup>	
BR	Ortalama	8,14E-07	8,54E-10	2,51E-05	2,03E-05	0,085742	0,999984	0,999969
	St. Sapma	1,39E-06	1,46E-09	1,49E-05	1,24E-05	0,053151	2,70E-05	5,40E-05
	En Büyük	2,65E-05	2,77E-08	1,67E-04	1,27E-04	0,529599	1,000000	0,999999
	En Küçük	2,37E-08	2,49E-11	4,99E-06	3,90E-06	0,016089	0,999482	0,998965
LM	Ortalama	1,85E-06	2,35E-09	4,06E-05	3,02E-05	0,120675	0,999957	0,999914
	St. Sapma	2,37E-06	3,01E-09	2,65E-05	1,97E-05	0,078812	5,54E-05	1,11E-04
	En Büyük	2,34E-05	2,97E-08	1,72E-04	1,42E-04	0,600326	<b>1,000000</b>	<b>1,000000</b>
	En Küçük	<b>8,96E-09</b>	<b>1,14E-11</b>	<b>3,38E-06</b>	<b>2,58E-06</b>	<b>0,010532</b>	0,999462	0,998924
SCG	Ortalama	1,15E-04	1,46E-07	3,56E-04	2,65E-04	1,042959	0,997311	0,994644
	St. Sapma	1,58E-04	2,01E-07	1,39E-04	1,09E-04	0,458909	0,003781	0,007369
	En Büyük	3,38E-03	4,30E-06	2,07E-03	1,62E-03	7,007706	0,999431	0,998863
	En Küçük	2,43E-05	3,11E-08	1,76E-04	1,26E-04	0,467767	0,918293	0,843262

IST'nin performans değerlendirme yöntemleri değerlerinin NARX ile eğitilmesi sonucu elde edilen performans ölçütlerinin tamamı için en iyi değerlere LM eğitim algoritmasına ve 6-(7)-8-1 model mimarisine sahip ağda ulaşılmıştır.

IST'nin kapanış fiyatının, fonun performans değerlendirme yöntemleri değerleriyle tahmin edilmesi için geliştirilen tüm NARX model mimarilerinin doğrulanması sonucunda elde edilen performans ölçütlerine ilişkin ortalama, standart sapma, en büyük ve en küçük değerler Çizelge 4.76'da gösterilmiştir.

**Çizelge 4.76.** IST'nin performans değerlendirme yöntemleri değerlerinin NARX ile doğrulanması sonucu elde edilen kapanış fiyatı tahminine ilişkin performans ölçüt değerleri

Performans Ölçütleri		SSE	MSE	RMSE	MAE	MAPE	R	R <sup>2</sup>
BR	Ortalama	-	-	-	-	-	-	-
	St. Sapma	-	-	-	-	-	-	-
	En Büyük	-	-	-	-	-	-	-
	En Küçük	-	-	-	-	-	-	-
LM	Ortalama	5,05E-07	3,00E-09	4,68E-05	3,31E-05	0,131600	0,999945	0,999890
	St. Sapma	6,08E-07	3,61E-09	2,84E-05	2,06E-05	0,081452	6,62E-05	1,32E-04
	En Büyük	6,20E-06	3,67E-08	1,92E-04	1,35E-04	0,566426	<b>0,999999</b>	<b>0,999999</b>
	En Küçük	<b>5,77E-09</b>	<b>3,43E-11</b>	<b>5,86E-06</b>	<b>3,88E-06</b>	<b>0,015876</b>	0,999324	0,998648
SCG	Ortalama	2,55E-05	1,51E-07	3,61E-04	2,70E-04	1,057654	0,997216	0,994460
	St. Sapma	3,84E-05	2,28E-07	1,45E-04	1,15E-04	0,483838	0,004556	0,008755
	En Büyük	9,15E-04	5,45E-06	2,33E-03	1,88E-03	8,223176	0,999550	0,999101
	En Küçük	4,46E-06	2,64E-08	1,62E-04	1,20E-04	0,471929	0,886584	0,786032


IST'nin performans değerlendirme yöntemleri değerlerinin NARX ile doğrulanması sonucu elde edilen performans ölçütlerinden SSE, MSE, RMSE için en iyi değerlere LM eğitim algoritmasına ve 6-(7)-7-1 model mimarisine sahip ağda ulaşılmıştır. En iyi MAE ve MAPE değerlerine LM eğitim algoritmasına ve 6-(7)-4-1 model mimarisine sahip ağda ulaşılmıştır. En iyi R ve R<sup>2</sup> değerlerine ise LM eğitim algoritmasına ve 6-(4)-8-1 model mimarisine sahip ağda ulaşılmıştır.

IST'nin kapanış fiyatının, fonun performans değerlendirme yöntemleri değerleriyle tahmin edilmesi için geliştirilen tüm NARX model mimarilerinin test edilmesi sonucunda elde edilen performans ölçütlerine ilişkin ortalama, standart sapma, en büyük ve en küçük değerler Çizelge 4.77'de gösterilmiştir. Geliştirilen tüm NARX mimarilerinin test edilmesi sonucunda elde edilen en iyi MSE, MAPE ve R performans ölçüt değerlerinin gecikme sayısı - gizli katman nöron sayısı çiftine göre değişimi ise sırasıyla Şekil 4.111, Şekil 4.112 ve Şekil 4.113'te gösterilmiştir.


**Çizelge 4.77.** IST'nin performans değerlendirme yöntemleri değerlerinin NARX ile test edilmesi sonucu elde edilen kapanış fiyatı tahminine ilişkin performans ölçüt değerleri

Performans Ölçütleri		SSE	MSE	RMSE	MAE	MAPE	R	R <sup>2</sup>
BR	Ortalama	1,53E-07	9,12E-10	2,61E-05	2,10E-05	0,088201	0,999984	0,999967
	St. Sapma	2,73E-07	1,63E-09	1,52E-05	1,26E-05	0,054332	2,85E-05	5,69E-05
	En Büyük	6,06E-06	3,61E-08	1,90E-04	1,44E-04	0,642109	0,999999	0,999999
	En Küçük	7,28E-09	4,31E-11	6,56E-06	4,67E-06	0,019190	0,999387	0,998774
LM	Ortalama	5,14E-07	3,05E-09	4,72E-05	3,33E-05	0,132381	0,999944	0,999888
	St. Sapma	6,42E-07	3,81E-09	2,87E-05	2,08E-05	0,083043	7,02E-05	1,40E-04
	En Büyük	7,22E-06	4,27E-08	2,07E-04	1,50E-04	0,657165	<b>1,000000</b>	<b>0,999999</b>
	En Küçük	<b>5,76E-09</b>	<b>3,41E-11</b>	<b>5,84E-06</b>	<b>3,68E-06</b>	<b>0,014796</b>	0,999197	0,998395
SCG	Ortalama	2,50E-05	1,49E-07	3,60E-04	2,69E-04	1,056478	0,997290	0,994601
	St. Sapma	3,42E-05	2,03E-07	1,38E-04	1,09E-04	0,461543	0,003770	0,007335
	En Büyük	7,61E-04	4,53E-06	2,13E-03	1,69E-03	7,359794	0,999618	0,999237
	En Küçük	3,67E-06	2,18E-08	1,48E-04	1,02E-04	0,405664	0,914635	0,836558


IST'nin performans değerlendirme yöntemleri değerlerinin NARX ile test edilmesi sonucu elde edilen performans ölçütlerinden için en iyi SSE, MSE, RMSE, R ve R<sup>2</sup> değerlerine LM eğitim algoritmasına ve 6-(3)-9-1 model mimarisine sahip ağda ulaşılmıştır. En iyi MAE ve MAPE değerlerine ise LM eğitim algoritmasına ve 6-(8)-2-1 model mimarisine sahip ağda ulaşılmıştır. Genel olarak performans ölçüt değerleri incelendiğinde en iyi performansın LM eğitim algoritmasına ve 6-(3)-9-1 model mimarisine sahip ağda elde edildiği sonucuna varılabilir.



**Şekil 4.111.** Performans değerlendirme yöntemleri değerleri ile IST'nin kapanış fiyatının tahmini için geliştirilen her bir NARX model mimarisi için gerçekleştirilen test iterasyonları sonucunda elde edilen en iyi MSE değerleri



**Şekil 4.112.** Performans değerlendirme yöntemleri değerleri ile IST'nin kapanış fiyatının tahmini için geliştirilen her bir NARX model mimarisi için gerçekleştirilen test iterasyonları sonucunda elde edilen en iyi MAPE değerleri



**Şekil 4.113.** Performans değerlendirme yöntemleri değerleri ile IST'nin kapanış fiyatının tahmini için geliştirilen her bir NARX model mimarisine için gerçekleştirilen test iterasyonları sonucunda elde edilen en iyi R değerleri

6-(3)-9-1 model mimarisine sahip NARX ağında eğitim algoritması çeşidine göre elde edilen eğitim, doğrulama ve test performans ölçüt sonuçları sırasıyla Çizelge 4.78, Çizelge 4.79 ve Çizelge 4.80'de gösterilmiştir.

**Çizelge 4.78.** IST'nin performans değerlendirme yöntemleri değerlerinin NARX ile eğitimi sonucu elde edilen kapanış fiyatı tahminine ilişkin performans ölçüt değerleri (model: 6-(3)-9-1)

Performans Ölçütleri	Eğitim Algoritması		
	BR	LM	SCG
SSE	8,30E-08	2,61E-08	4,11E-05
MSE	8,68E-11	3,31E-11	5,22E-08
RMSE	9,32E-06	5,76E-06	2,29E-04
MAE	6,64E-06	4,41E-06	1,61E-04
MAPE	0,026365	0,017608	0,644397
R	0,999999	1,000000	0,999083
R <sup>2</sup>	0,999997	0,999999	0,998167

**Çizelge 4.79.** IST'nin performans değerlendirme yöntemleri değerlerinin NARX ile doğrulanması sonucu elde edilen kapanış fiyatı tahminine ilişkin performans ölçüt değerleri (model: 6-(3)-9-1)

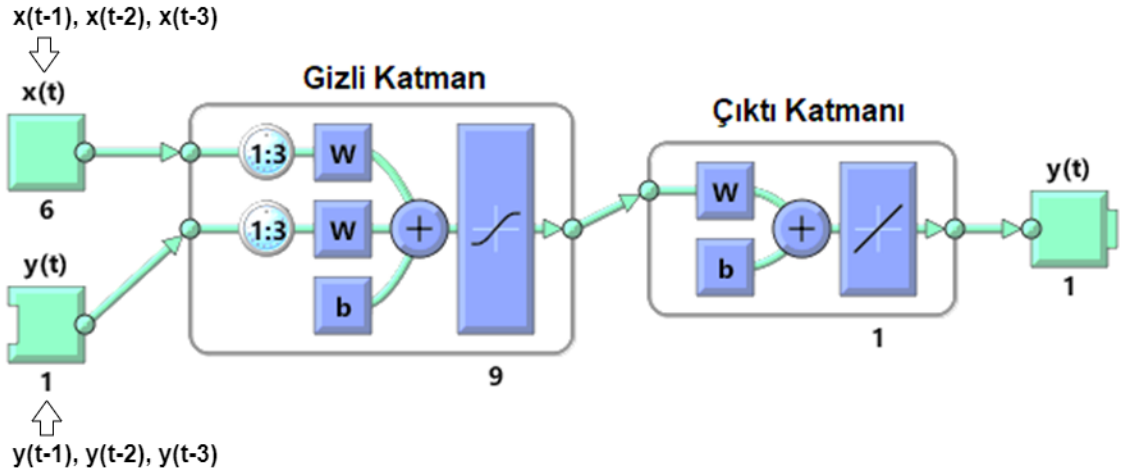
Performans Ölçütleri	Eğitim Algoritması		
	BR	LM	SCG
SSE	-	4,97E-08	8,66E-06
MSE	-	2,94E-10	5,12E-08
RMSE	-	1,71E-05	2,26E-04
MAE	-	5,76E-06	1,62E-04
MAPE	-	0,022838	0,636126
R	-	0,999995	0,999005
R <sup>2</sup>	-	0,999990	0,998011

**Çizelge 4.80.** IST'nin performans değerlendirme yöntemleri değerlerinin NARX ile test edilmesi sonucu elde edilen kapanış fiyatı tahminine ilişkin performans ölçüt değerleri (model: 6-(3)-9-1)

Performans Ölçütleri	Eğitim Algoritması		
	BR	LM	SCG
SSE	1,53E-08	5,76E-09	8,85E-06
MSE	9,07E-11	3,41E-11	5,23E-08
RMSE	9,52E-06	5,84E-06	2,29E-04
MAE	7,18E-06	4,64E-06	1,61E-04
MAPE	0,027977	0,018583	0,646924
R	0,999999	1,000000	0,999000
R <sup>2</sup>	0,999998	0,999999	0,998001


Bahsi geçen model mimarisi Şekil 4.114'te gösterilmiştir.






**Şekil 4.114.** Performans değerlendirme yöntemleri değerleri ile IST'nin kapanış fiyatının tahmini için geliştirilen NARX model mimarisi (eğitim algoritması: LM, model: 6-(3)-9-1)

Performans ölçütlerinden MSE'nin eğitim, doğrulama ve test için performansı Şekil 4.115'te gösterilmektedir. Şekilden en iyi doğrulama performansının  $2,9411E-10$  MSE ile 12. eğitim turunda elde edildiği sonucu çıkarılabilir.




**Şekil 4.115.** Performans değerlendirme yöntemleri değerleri ile IST'nin kapanış fiyatının tahmini için geliştirilen NARX'in MSE Performansı (eğitim algoritması: LM, model: 6-(3)-9-1)

Şekil 4.116, IST'nin performans değerlendirme yöntemleri değerleri ile kapanış fiyatının tahminine ilişkin geliştirilen NARX'in eğitim durumunu özetlemektedir.




**Şekil 4.116.** Performans değerlendirme yöntemleri değerleri ile IST'nin kapanış fiyatının tahmini için geliştirilen NARX'in eğitim durumu (eğitim algoritması: LM, model: 6-(3)-9-1)

Eğitilmiş ağıın eğitim, doğrulama ve test hatalarından oluşan bir hata histogramı Şekil 4.117'de gösterilmiştir. Şekil incelendiğinde hataların çoğunun  $\pm 1,5E-05$  aralığında olduğu ve maksimum hatanın yaklaşık olarak 0,0002 olduğu tespit edilebilir. Ayrıca sıfır hata noktası  $-8,6E-06$  merkezli tanımlanmış bölmenin altına düşmektedir. Bu nedenle, elde edilen hataya bağlı olarak, eğitilmiş ağ, kapanış fiyatı tahmini için kullanılabilir.




**Şekil 4.117.** Performans değerlendirme yöntemleri değerleri ile IST'nin kapanış fiyatının tahmini için geliştirilen NARX'in hata histogramı (eğitim algoritması: LM, model: 6-(3)-9-1)

Ağın gerçekleşen ve tahmin edilen değerler arasındaki regresyon grafiği Şekil 4.118'de gösterilmiştir. Şekilden de görüldüğü üzere NARX modelinin eğitim, doğrulama ve test verileri için elde edilen korelasyon katsayısı değerleri sırasıyla 1, 0,99999 ve 1'dir. Tüm veriler için elde edilen korelasyon katsayısı değeri ise 1'dir. Bu durum, elde edilen tahmin modelinin çıktılarının gerçekleşen değerlerle uyum içinde olduğu ve bu değerler arasında sapma olmadığını göstermektedir.




**Şekil 4.118.** Performans değerlendirme yöntemleri değerleri ile IST'nin kapanış fiyatının tahmini için geliştirilen NARX'in regresyon grafikleri (eğitim algoritması: LM, model: 6-(3)-9-1)

Şekil 4.119, eğitilmiş çıktı değeri ile hedef (gerçekleşen) değerini karşılaştırmasını göstermektedir.




**Şekil 4.119.** Performans değerlendirme yöntemleri değerleri ile IST'nin kapanış fiyatının tahmini için geliştirilen NARX'in tahmin sonuçları (eğitim algoritması: LM, model: 6-(3)-9-1)

Şekil 4.120, hata otokorelasyon fonksiyonunu göstermekte ve tahmin hatalarının zamanla nasıl ilişkili olduğunu açıklamaktadır. Şekilde, sıfır gecikmeli korelasyon dışındaki korelasyonlar, %95 güven sınırları içinde kalmamasına rağmen sıfır etrafında dalgalanmaktadır. Bu nedenle model yeterli görülmektedir.



**Şekil 4.120.** Performans değerlendirme yöntemleri değerleri ile IST'nin kapanış fiyatının tahmini için geliştirilen NARX'in hata otokorelasyonları (eğitim algoritması: LM, model: 6-(3)-9-1)

Şekil 4.121'de gösterilen girdi-hata çapraz korelasyon fonksiyonundaki korelasyon değerlerinin tamamı güven sınırları içerisinde olmasa da sıfır civarında dalgalanmaktadır. Bu da yeterli bir tahmin modelinin olduğunu göstermektedir.



**Şekil 4.121.** Performans değerlendirme yöntemleri değerleri ile IST'nin kapanış fiyatının tahmini için geliştirilen NARX'in girdi-hata çapraz-korelasyonları (eğitim algoritması: LM, model: 6-(3)-9-1)

#### 4.2.3. Performans değerlendirme yöntemleri değerleri ile yatırım fonu kapanış fiyatının tahmin edilmesi için geliştirilen modellerin yeni tarihli veriler ile ek testlere tabi tutulması

Performans değerlendirme yöntemleri değerleri ile yatırım fonu kapanış fiyatının tahmin edilmesi için geliştirilen tek gizli katmanlı YSA, iki gizli katmanlı YSA ve NARX modelleri yeni tarihli veriler ile ek testlere tabi tutularak modellerin istikrarlı bir şekilde çalışması durumu kontrol edilmiştir.


##### 4.2.3.1. En fazla sayıda portföye dağılan yatırım fonuna ilişkin bulgular

DBP'nin kapanış fiyatının performans değerlendirme yöntemleri değerlerinden faydalanılarak tahmin edilmesi için geliştirilen tek gizli katmanlı YSA, iki gizli katmanlı YSA ve NARX modellerinden optimal sonuç veren modellere ilişkin bilgiler Çizelge 4.81'de gösterilmiştir.


**Çizelge 4.81.** DBP'nin kapanış fiyatının performans değerlendirme yöntemleri değerlerinden faydalanılarak tahmin edilmesi için geliştirilen ve optimal sonuç veren tek gizli katmanlı YSA, iki gizli katmanlı YSA ve NARX model mimarileri

Yöntem	Optimal Sonucu Veren	
	Eğitim Algoritması	Model
YSA-1	BR	6-7-1
YSA-2	LM	6-8-9-1
NARX	BR	6-(1)-9-1

Geliştirilen modellerin ek testlere tabi tutulması için DBP yatırım fonunun 2021 yılı Temmuz-Aralık dönemindeki 125 iş gününe ait verilerinden yararlanılmıştır. DBP yatırım fonu için 125 iş gününe ait kapanış fiyatlarıyla, optimal sonuç veren tek gizli katmanlı YSA, iki gizli katmanlı YSA ve NARX model mimarileri yardımıyla elde edilen kapanış fiyatı tahminleri arasındaki ilişki sırasıyla Şekil 4.122, Şekil 4.123 ve Şekil 4.124'te gösterilmiştir.




**Şekil 4.122.** Performans değerlendirme yöntemleri değerleri ile DBP'nin kapanış fiyatının tahmini için geliştirilen ve optimal sonuç veren tek gizli katmanlı YSA'nın ek testi sonrasında elde edilen tahmin sonuçları (eğitim algoritması: BR, model: 6-7-1)



**Şekil 4.123.** Performans değerlendirme yöntemleri değerleri ile DBP'nin kapanış fiyatının tahmini için geliştirilen ve optimal sonuç veren iki gizli katmanlı YSA'nın ek testi sonrasında elde edilen tahmin sonuçları (eğitim algoritması: LM, model: 6-8-9-1)





**Şekil 4.124.** Performans değerlendirme yöntemleri değerleri ile DBP'nin kapanış fiyatının tahmini için geliştirilen ve optimal sonuç veren NARX'in ek testi sonrasında elde edilen tahmin sonuçları (eğitim algoritması: BR, model: 6-(1)-9-1)

Şekiller incelendiğinde DBP'nin kapanış fiyatı tahmini hatalarının 77. işgünü itibariyle arttığı gözlenmektedir. Fon için 77. işgünü 25.10.2021 tarihine denk gelmektedir. Tahmin hatalarının artmasında majör makroekonomik değişikliklerin önemli etkisi olduğu düşünülmektedir. Hatırlanacağı üzere yatırım fonu kapanış fiyatının fon portföy dağılımından faydalanılarak tahmin edilmesi için geliştirilen modellerin yeni tarihli veriler ile ek testlere tabi tutulması sonucunda DBP'nin kapanış fiyatı tahmini hataları 79. iş günü itibariyle artmaktadır. Bu durum tahmin hatalarının artmasında majör makroekonomik değişikliklerin önemli etkisi olduğu görüşünü güçlendirmektedir. DBP'nin risk değeri 5'tir. Risk skalası 1 ile 7 arasında değer almaktadır. Risk skalasında risk, risk değerinin artması ile artmaktadır. Buradan hareketle fonun orta derecede riskli olduğu ve ekonomideki hareketlilikten etkilenebileceği kanısına varılabilir.

DBP'nin 125 iş günlük periyot için ek testlere tabi tutulması sonucunda elde edilen performans ölçüt değerleri Çizelge 4.82'de gösterilmiştir. Çizelgeden hareketle DBP

yatırım fonunun kapanış fiyatının tahmininde NARX'in tek gizli katmanlı YSA ve iki gizli katmanlı YSA'ya kıyasla çok daha isabetli tahminler ürettiği sonucuna varılabilir.

**Çizelge 4.82.** DBP'nin 125 iş günlük yeni tarihli veri için tek gizli katmanlı YSA, iki gizli katmanlı YSA ve NARX ile ek testlere tabi tutulması sonucu elde edilen kapanış fiyatı tahminlerine ilişkin performans ölçüt değerleri

Yöntem	Performans Ölçütü				
	SSE	MSE	RMSE	MAE	MAPE
YSA-1	0,001993	1,59E-05	0,003993	0,001859	3,345001
YSA-2	0,003713	2,97E-05	0,005450	0,003006	5,434838
NARX	0,0000941	7,18E-07	0,000848	0,000540	0,997322

#### 4.2.3.2. En çok işlem gören yatırım fonuna ilişkin bulgular


IST'nin kapanış fiyatının performans değerlendirme yöntemleri değerlerinden faydalanılarak tahmin edilmesi için geliştirilen tek gizli katmanlı YSA, iki gizli katmanlı YSA ve NARX modellerinden optimal sonuç veren modellere ilişkin bilgiler Çizelge 4.83'te gösterilmiştir.

**Çizelge 4.83.** IST'nin kapanış fiyatının performans değerlendirme yöntemleri değerlerinden faydalanılarak tahmin edilmesi için geliştirilen ve optimal sonuç veren tek gizli katmanlı YSA, iki gizli katmanlı YSA ve NARX model mimarileri


Yöntem	Optimal Sonucu Veren	
	Eğitim Algoritması	Model
YSA-1	BR	6-10-1
YSA-2	LM	6-9-9-1
NARX	LM	6-(3)-9-1

Geliştirilen modellerin ek testlere tabi tutulması için IST yatırım fonunun 2021 yılı Temmuz-Aralık dönemindeki 125 iş gününe ait verilerinden yararlanılmıştır. IST yatırım fonu için 125 iş gününe ait kapanış fiyatlarıyla, optimal sonuç veren tek gizli katmanlı YSA, iki gizli katmanlı YSA ve NARX model mimarileri yardımıyla elde edilen kapanış


fiyatı tahminleri arasındaki ilişki sırasıyla Şekil 4.125, Şekil 4.126 ve Şekil 4.127’de gösterilmiştir.



**Şekil 4.125.** Performans değerlendirme yöntemleri değerleri ile IST'nin kapanış fiyatının tahmini için geliştirilen ve optimal sonuç veren tek gizli katmanlı YSA'nın ek testi sonrasında elde edilen tahmin sonuçları (eğitim algoritması: BR, model: 6-10-1)



**Şekil 4.126.** Performans değerlendirme yöntemleri değerleri ile IST'nin kapanış fiyatının tahmini için geliştirilen ve optimal sonuç veren iki gizli katmanlı YSA'nın ek testi sonrasında elde edilen tahmin sonuçları (eğitim algoritması: LM, model: 6-9-9-1)



**Şekil 4.127.** Performans değerlendirme yöntemleri değerleri ile IST'nin kapanış fiyatının tahmini için geliştirilen ve optimal sonuç veren NARX'in ek testi sonrasında elde edilen tahmin sonuçları (eğitim algoritması: LM, model: 6-(3)-9-1)

Şekiller incelendiğinde IST'nin kapanış fiyatı tahmini hatalarının 12. işgünü itibariyle arttığı gözlenmektedir. Fon için 12. işgünü 19.07.2021 tarihine denk gelmektedir. İlgili tarihten önceki iki gün hafta sonu tatili, sonraki 6 gün ise 4 gün Kurban Bayramı tatiline ve iki gün hafta sonu tatiline denk gelmektedir. Tatil sürelerinin uzun olduğu bu gibi dönemlerde yatırımcı davranışlarında çeşitli değişimler meydana gelmektedir. Örneğin böyle dönemlerde özellikle borsada yatırımlarını değerlendiren yatırımcılar tatil öncesinde nakde dönerek yatırımlarını borçlandırma araçlarına yönlendirmektedir. İlgili fon kısa vadeli borçlanma araçlarını içerdiğinden dolayı bu durum tahmin hatalarına yol açmış şüphesini kuvvetlendirmektedir.

IST'nin 125 iş günlük periyot için ek testlere tabi tutulması sonucunda elde edilen performans ölçüt değerleri Çizelge 4.84'te gösterilmiştir. Çizelgeden hareketle IST yatırım fonunun kapanış fiyatının tahmininde NARX'in tek gizli katmanlı YSA ve iki gizli katmanlı YSA'ya kıyasla daha isabetli tahminler ürettiği sonucuna varılabilir.

**Çizelge 4.84.** IST'nin 125 iş günlük yeni tarihli veri için tek gizli katmanlı YSA, iki gizli katmanlı YSA ve NARX ile ek testlere tabi tutulması sonucu elde edilen kapanış fiyatı tahminlerine ilişkin performans ölçüt değerleri

Yöntem	Performans Ölçütü				
	SSE	MSE	RMSE	MAE	MAPE
YSA-1	0,002564	2,05E-05	0,004529	0,002977	7,958325
YSA-2	0,004128	3,30E-05	0,005747	0,005400	14,76774
NARX	0,0000215	1,72E-07	0,000415	0,000373	1,010523

## 5. TARTIŞMA ve SONUÇ

Bu çalışmada ilk olarak, YSA ve NARX metodolojisine dayalı olarak, menkul kıymet yatırım fonu kapanış fiyatının fon portföy dağılımından faydalanılarak tahmini için genel ve doğru modeller geliştirilmiştir. Kapanış fiyatı (net aktif değeri) tahminleri, en fazla sayıda portföy kalemine dağılan menkul kıymet yatırım fonlarından biri olan ve 16 portföy kalemine dağılan “Deniz Portföy Birinci Değişken Fon (DBP)” ile 2017-2021/6 yılları arasında en fazla işlem hacmine sahip olan “İstanbul Portföy Kısa Vadeli Borçlanma Araçları Fonu (IST)” verilerinden hareketle gerçekleştirilmiştir. Modellerin girdileri, menkul kıymet yatırım fonunun portföy dağılımını oluşturan hisse senedi, devlet tahvili, hazine bonusu, döviz kamu iç borçlanma araçları, döviz ödemeli bono, döviz ödemeli tahvil, finansman bonusu, özel sektör tahvili, banka bonusu, varlığa dayalı menkul kıymetler, gayri menkul sertifikası, eurobonds, kamu dış borçlanma araçları, özel sektör dış borçlanma araçları, Takasbank para piyasası, kamu kira sertifikaları, kamu kira sertifikaları (TL), kamu kira sertifikaları (döviz), özel sektör kira sertifikaları, kamu yurt dışı kira sertifikaları, özel sektör yurt dışı kira sertifikaları, vadeli mevduat, mevduat (TL), mevduat (döviz), mevduat (altın), katılım hesabı, katılma hesabı (TL), katılma hesabı (döviz), katılma hesabı (altın), repo, ters-repo, kıymetli madenler, kıymetli madenler cinsinden borsa yatırım fonları, kıymetli madenler kamu borçlanma araçları, kıymetli madenler kamu kira sertifikaları, yabancı menkul kıymet, yabancı borçlanma aracı, yabancı kamu borçlanma araçları, yabancı özel sektör borçlanma araçları, yabancı hisse senedi, yabancı borsa yatırım fonları, fon katılma belgesi, yatırım fonları katılma payları, borsa yatırım fonları katılma payları, gayrimenkul yatırım fon katılma payları, girişim sermayesi yatırım fon katılma payları, türev araçları, vadeli işlemler nakit teminatları ve diğer gibi kalemlerin yüzdelik ağırlığıdır. Modellerin çıktısı ise menkul kıymet yatırım fonu kapanış fiyatıdır.

Yapılan analizler sonrasında DBP'nin kapanış fiyatının fon portföy dağılımından faydalanılarak tahmini için önerilen tek gizli katmanlı YSA model mimarisi; gizli katmanda 10 nöron, gizli katman aktivasyon fonksiyonu olarak tanjant lojistik sigmoid, çıktı aktivasyon fonksiyonu olarak lineer ve eğitim yöntemi olarak BR içermektedir. IST'nin kapanış fiyatının fon portföy dağılımından faydalanılarak tahmini için önerilen

tek gizli katmanlı YSA model mimarisi ise; gizli katmanda 10 nöron, gizli katman aktivasyon fonksiyonu olarak tanjant lojistik sigmoid, çıktı aktivasyon fonksiyonu olarak lineer ve eğitim yöntemi olarak BR geri yayılımı içermektedir.

Yapılan analizler sonrasında DBP'nin kapanış fiyatının fon portföy dağılımından faydalanılarak tahmini için önerilen iki gizli katmanlı YSA model mimarisi; birinci gizli katmanda 5 nöron, ikinci gizli katmanda 10 nöron, birinci gizli katman aktivasyon fonksiyonu olarak tanjant lojistik sigmoid, ikinci gizli katman aktivasyon fonksiyonu olarak tanjant lojistik sigmoid, çıktı aktivasyon fonksiyonu olarak lineer ve eğitim yöntemi olarak BR içermektedir. IST'nin kapanış fiyatının fon portföy dağılımından faydalanılarak tahmini için önerilen iki gizli katmanlı YSA model mimarisi ise; birinci gizli katmanda 6 nöron, ikinci gizli katmanda 5 nöron, birinci gizli katman aktivasyon fonksiyonu olarak tanjant lojistik sigmoid, ikinci gizli katman aktivasyon fonksiyonu olarak tanjant lojistik sigmoid, çıktı aktivasyon fonksiyonu olarak lineer ve eğitim yöntemi olarak BR geri yayılımı içermektedir.

DBP'nin kapanış fiyatının fon portföy dağılımından faydalanılarak tahmini için önerilen NARX model mimarisi gizli katmanda 5 nöron, giriş ve çıkışta 1 gecikme bağlantısı, gizli katman aktivasyon fonksiyonu olarak tanjant lojistik sigmoid, çıktı aktivasyon fonksiyonu olarak lineer ve eğitim yöntemi olarak BR içermektedir. IST'nin kapanış fiyatının fon portföy dağılımından faydalanılarak tahmini için önerilen NARX model mimarisi ise gizli katmanda 10 nöron, giriş ve çıkışta 2 gecikme bağlantısı, gizli katman aktivasyon fonksiyonu olarak tanjant lojistik sigmoid, çıktı aktivasyon fonksiyonu olarak lineer ve eğitim yöntemi olarak LM içermektedir.

Analizler neticesinde elde edilen SSE, MSE, RMSE, MAE, MAPE, R ve  $R^2$  performans ölçütleri dikkate alınarak önerilen modellerin uygulanabilirliği irdelenmiştir. Elde edilen bulgular, DBP'nin kapanış fiyatının fon portföy dağılımından faydalanılarak tahmin edilmesi için önerilen tek gizli katmanlı YSA, iki gizli katmanlı YSA ve NARX modeli ile IST'nin kapanış fiyatının fon portföy dağılımından faydalanılarak tahmin edilmesi için önerilen tek gizli katmanlı YSA, iki gizli katmanlı YSA ve NARX modellerinin test sonuçlarına bakıldığında, kapanış fiyatlarıyla fon portföy dağılımı arasında çok güçlü bir

ilişki olduğu görülmektedir. Buradan hareketle bahsi geçen modellerin çok yüksek tahmin kabiliyetine sahip olduğu ifade edilebilir. Elde edilen bulgulardan hareketle, yatırımcıların yalnızca fon dağılımlarından yararlanarak yatırım fonunun kapanış fiyatını doğru bir şekilde tahmin edebileceği sonucuna varılabilir. Sonuçlar yatırım fonlarının geçmiş portföy bileşimlerinin gelecekteki performans üzerindeki etkisini doğrulamaktadır. Elde edilen bulgulardan hareketle yapılacak diğer bir çıkarımsa NARX modelleri ile elde edilen kapanış fiyatı tahminlerinin tek gizli katmanlı YSA ve iki gizli katmanlı YSA modelleri ile elde edilen kapanış fiyatı tahminlerinden daha başarılı olmasıdır.

Tez çalışmasında ikinci olarak, menkul kıymet yatırım fonu kapanış fiyatının performans değerlendirme yöntemleri değerlerinden faydalanılarak tahmini için genel ve doğru modeller geliştirilmiştir. Kapanış fiyatı tahminlerinde de DBP ile IST fonlarına ilişkin verilerinden faydalanılmıştır. Modellerin girdileri, portföy risk ve performans ölçütlerinden Standart sapma, Beta, Jensen alfa, Sharpe oranı, Treynor oranı ve Enformasyon oranı değerleridir. Modellerin çıktısı ise menkul kıymet yatırım fonu kapanış fiyatıdır.

Yapılan analizler sonrasında DBP'nin kapanış fiyatının performans değerlendirme yöntemleri değerlerinden faydalanılarak tahmini için önerilen tek gizli katmanlı YSA model mimarisi; gizli katmanda 7 nöron, gizli katman aktivasyon fonksiyonu olarak tanjant lojistik sigmoid, çıktı aktivasyon fonksiyonu olarak lineer ve eğitim yöntemi olarak BR içermektedir. IST'nin kapanış fiyatının performans değerlendirme yöntemleri değerlerinden faydalanılarak tahmini için önerilen tek gizli katmanlı YSA model mimarisi ise; gizli katmanda 10 nöron, gizli katman aktivasyon fonksiyonu olarak tanjant lojistik sigmoid, çıktı aktivasyon fonksiyonu olarak lineer ve eğitim yöntemi olarak BR içermektedir.

DBP'nin kapanış fiyatının performans değerlendirme yöntemleri değerlerinden faydalanılarak tahmini için önerilen iki gizli katmanlı YSA model mimarisi; birinci gizli katmanda 8 nöron, ikinci gizli katmanda 9 nöron, birinci gizli katman aktivasyon fonksiyonu olarak tanjant lojistik sigmoid, ikinci gizli katman aktivasyon fonksiyonu



olarak tanjant lojistik sigmoid, çıktı aktivasyon fonksiyonu olarak lineer ve eğitim yöntemi olarak LM içermektedir. IST'nin kapanış fiyatının performans değerlendirme yöntemleri değerlerinden faydalanılarak tahmini için önerilen iki gizli katmanlı YSA model mimarisi ise; birinci gizli katmanda 9 nöron, ikinci gizli katmanda 9 nöron, birinci gizli katman aktivasyon fonksiyonu olarak tanjant lojistik sigmoid, ikinci gizli katman aktivasyon fonksiyonu olarak tanjant lojistik sigmoid, çıktı aktivasyon fonksiyonu olarak lineer ve eğitim yöntemi olarak LM geri yayılımı içermektedir.

DBP'nin kapanış fiyatının performans değerlendirme yöntemleri değerlerinden faydalanılarak tahmini için önerilen NARX model mimarisi gizli katmanda 9 nöron, giriş ve çıkışta 1 gecikme bağlantısı, gizli katman aktivasyon fonksiyonu olarak tanjant lojistik sigmoid, çıktı aktivasyon fonksiyonu olarak lineer ve eğitim yöntemi olarak BR içermektedir. IST'nin kapanış fiyatının performans değerlendirme yöntemleri değerlerinden faydalanılarak tahmini için önerilen NARX model mimarisi ise gizli katmanda 9 nöron, giriş ve çıkışta 3 gecikme bağlantısı, gizli katman aktivasyon fonksiyonu olarak tanjant lojistik sigmoid, çıktı aktivasyon fonksiyonu olarak lineer ve eğitim yöntemi olarak LM içermektedir.

Hem DBP'nin hem de IST'nin kapanış fiyatının performans değerlendirme yöntemleri değerlerinden faydalanılarak tahmin edilmesi için önerilen tek gizli katmanlı YSA, iki gizli katmanlı YSA ve NARX modellerinin test sonuçlarına bakıldığında, kapanış fiyatıyla performans değerlendirme yöntemleri değerleri arasında çok güçlü bir ilişki olduğu sonucuna varılabilir. Elde edilen bulgulardan hareketle, yatırımcıların performans değerlendirme yöntemleri değerleri ile yatırım fonunun kapanış fiyatını doğru bir şekilde tahmin edebileceği sonucuna varılabilir. Elde edilen bulgulardan hareketle yapılacak diğer bir çıkarımsa NARX modelleri ile elde edilen kapanış fiyatı tahminlerinin tek gizli katmanlı YSA ve iki gizli katmanlı YSA modelleri ile elde edilen kapanış fiyatı tahminlerinden daha başarılı olmasıdır. Eğer eğitim algoritmaları açısından bakılacak olursa da BR ve LM algoritmalarının SCG algoritmasına kıyasla daha iyi tahmin doğruluğu sağladığı ve genel olarak BR ve LM algoritmalarının birbirine yakın tahmin değerleri sağladığı sonucu çıkarılabilir.

Yatırım fonu kapanış fiyatının tahminine ilişkin önceki araştırmalarda elde edilen performans ölçüt değerleri ile tez çalışmasının iki amacının performans ölçüt değerleri göz önüne alındığında her ne kadar aynı yatırım fonları üzerine çalışılmamış olsa da optimal SSE, MSE, RMSE, MAPE, R ve R<sup>2</sup> değerlerine, tez çalışmasının ikinci amacı olan yatırım fonu kapanış fiyatının performans değerlendirme yöntemleri değerlerinden faydalanılarak tahmin edilmesi için gerçekleştirilen analizler neticesinde elde edilmiştir. En iyi MAPE değerine ise Hota vd. (2018) tarafından gerçekleştirilen çalışmada Yunus Sürüsü Algoritması ile hibritleştirilmiş Aşırı Öğrenme Makinesi modeli ile ulaşılmıştır. Yatırım fonu kapanış fiyatının tahminine ilişkin önceki araştırmalarda elde edilen performans ölçüt değerleri ile tez çalışmasının iki amacının performans ölçüt değerleri EK 1’de ayrıntılı olarak gösterilmiştir.

Geliştirilen model mimarilerinden optimal sonucu veren model mimarileri, 2021 yılı Temmuz – Aralık dönemi içerisindeki toplam 125 iş günlük verilerle ek teste tabi tutularak modellerin kararlılığı sınanmıştır. Yatırım fonu kapanış fiyatının tahmini üzerine gerçekleştirilmiş önceki çalışmalarda ek test işlemleri gerçekleşmediğinden bu durum bilime katkı açısından önemli olarak görülmektedir. Ek test sonuçları da her iki amaç için NARX modelleri ile elde edilen kapanış fiyatı tahminlerinin tek gizli katmanlı YSA ve iki gizli katmanlı YSA modelleri ile elde edilen kapanış fiyatı tahminlerinden daha başarılı olduğunu doğrulamaktadır.

Geliştirilen mimarilerde gizli katman nöron sayısı 1 ile 10 arasında sınırlandırılmıştır. Yapılan analizlerde gizli katman nöron sayısının 10 kat artması (1 ile 100 arasında sınırlandırılması) toplam analiz sayısının 25200’den 2412000’e yükselmesine yol açmakta ve analiz süresinin yaklaşık 95 kat artmasına sebep olmaktadır. Analizler Intel(R) Core(TM) i5-7200U CPU @ 2.50GHz 2.70 GHz işlemciye ve 8 GB Ram’a sahip bir dizüstü bilgisayarda gerçekleştirilmiştir. İleriki çalışmalarda analizler daha donanımlı bir bilgisayarda yapılarak gizli katman nöron sayısı aralığı artırılıp daha isabetli yatırım fonu kapanış fiyatı tahminleri gerçekleştirilebilir.

Elde edilen sonuçlar; yatırımcılar, mali müşavirler, fon yöneticileri ve emeklilik planı yöneticileri için büyük bir öneme sahiptir. Çalışmada kullanılan algoritmalar kolaylıkla

uygulanabilir ve fon seçimini iyileştirmek için kullanılabilir. Daha da önemlisi, çalışmada kullanılan tüm bilgiler halka açık kaynaklarda ve ticari veri sağlayıcılarında mevcut olduğundan, veriye erişim imkânı yüksek düzeydedir.

Doğal olarak, tüm yatırımcılar yatırım fonlarının kapanış fiyatının ve getiri düzeyinin tahmininde makine öğrenmesi yöntemlerini uygulamak için gerekli kaynaklara sahip değildir. Ancak, bireysel yatırımcıların yatırım fonu kararları için takip ettikleri bağımsız analistler, tavsiyelerini vermek için tez çalışmasında kullanılan algoritmaları ve verileri kullanabilir.

Bu çalışmada önerilen modelleri değiştirerek veya bu modeller yardımıyla yeni bir model tanımlayarak, yatırımcıların karlı yatırım fonlarına akıllıca yatırım yapmasına ve daha iyi bir karar vermesine yardımcı olabilecek çalışmalara imza atılabilir. İleriki çalışmalarda aynı modelin türevleriyle fon alma-almama ve alternatifler arasından fon seçimi konularına da odaklanılabilir.

Son olarak YSA ve NARX gibi makine öğrenmesi algoritmaları problemleri analiz etmede çok sayıda örnekle daha başarılı olmaktadır. Bundan dolayı yatırım fonlarının kapanış fiyatının (net aktif değerinin) tahmin edilmesinde bahsi geçen yatırım fonuna ilişkin dikkate alınan geçmiş verilerin örneklem büyüklüğünün mümkün mertebe büyük tutulması gerekir.

## KAYNAKLAR

- Abdallah, M., Talib, M. A., Feroz, S., Nasir, Q., Abdalla, H., & Mahfood, B. (2020). Artificial intelligence applications in solid waste management: A systematic research review. *Waste Management*, 109, 231-246. <https://doi.org/10.1016/j.wasman.2020.04.057>
- Aji, G. K., Bachtiar, W. F., Yuliando, H., & Suwondo, E. (2019). Dynamic Modeling of the Drying Process of Corn Grains using Neural Networks. *agriTECH*, 39(3), 251-257. <https://doi.org/10.22146/agritech.35848>
- Akel, V., & Karacameydan, F. (2012). Yatırım Fonları Net Varlık Değerlerinin Yapay Sinir Ağları Yöntemiyle Tahmin Edilmesi. *Anadolu Üniversitesi Sosyal Bilimler Dergisi*, 12(2), 87-106.
- Akshaya M., S., & Ganapathi, P. (2020). A review of machine learning methods applied for handling zero-day attacks in the cloud environment. P. Ganapathi & D. Shanmugapriya (Eds.), *Handbook of Research on Machine and Deep Learning Applications for Cyber Security* (ss. 364-387). IGI Global. <https://doi.org/10.4018/978-1-5225-9611-0.ch017>
- Aktifportföy. (2021). *Yatırım fonları nedir?* 25.09.2021 tarihinde <https://www.aktifportfoy.com.tr/fon-kategori-detay/1> adresinden erişildi.
- Altay, E. (2015). *Bankacılıkta risk: piyasa riski kredi riski ve operasyonel riskin ölçümü ve yönetimi* (2.baskı). Derin Yayınları.
- Amaratunga, T. (2021). *Deep Learning on Windows: Building Deep Learning Computer Vision Systems on Microsoft Windows*. Apress Media LLC. <https://doi.org/10.1007/978-1-4842-6431-7>
- Amirkhani, S., Tootchi, A., & Chaibakhsh, A. (2021). Fault detection and isolation of gas turbine using series-parallel NARX model. *ISA Transactions*. <https://doi.org/https://doi.org/10.1016/j.isatra.2021.03.019>
- Anbar, A. (2011). *Yapılandırılmış Finans*. Ekin Basım Yayın Dağıtım.
- Anish, C. M., & Majhi, B. (2015a, 15-17 Oct. 2015). An ensemble model for Net asset value prediction. 2015 IEEE Power, Communication and Information Technology Conference (PCITC),
- Anish, C. M., & Majhi, B. (2015b). Net asset value prediction using FLANN model. *International Journal of Science and Research*, 4(2), 2222-2227.
- Anish, C. M., & Majhi, B. (2016, 10-11 March 2016). Prediction of mutual fund net asset value using low complexity feedback neural network. 2016 IEEE International Conference on Current Trends in Advanced Computing (ICCTAC),
- Arıkan Kargı, V. S. (2015). *Yapay Sinir Ağ Modelleri ve Bir Tekstil Firmasında Uygulama*. Ekin Yayınevi.
- Arslan, M., & Arslan, S. (2010). Yatırım fonu performans ölçütleri, regresyon analizleri ve MANOVA yöntemine göre A, B ve borsa yatırım fonlarının karşılaştırmalı analizi. *İşletme Araştırmaları Dergisi*, 2(2), 3-20.
- Aydemir, E. (2018). *Weka İle Yapay Zekâ: Makine Öğrenmesi - Yapay Sinir Ağları - Derin Öğrenme* (1.baskı). Seçkin Yayıncılık.
- Aytekin, S. (2018). Evaluation of Fund Portfolio Managers' Return Performance in Terms of Systematic and Unsystematic Risk Factors *Asian Research Journal of Business Management*, 6(1), 1-11. <https://doi.org/10.24214/ARJBM/6/1/111>

- Aytekin, S., & Güler Özçalık, S. (2019, 25-26 April, 2019). Teori ve uygulama birlikte hareket eder mi? Portföy yönetici getirisi ve portföy performansı karşılaştırılması. 10th International Congress on Entrepreneurship (ICE 2019), Manisa, Turkey.
- Azim, R. A. (2020). Prediction of multiphase flow rate for artificially flowing wells using rigorous artificial neural network technique. *Flow Measurement and Instrumentation*, 76, 101835. <https://doi.org/j.flowmeasinst.2020.101835>
- Bacon, C. R. (2008). *Practical Portfolio Performance Measurement and Attribution* (2.baskı). John Wiley & Sons Ltd.
- Baker, H. K., Filbeck, G., & Kiyamaz, H. (2015). *Mutual funds and exchange-traded funds: building blocks to wealth*. Oxford University Press.
- Bariani, P. F., Bruschi, S., & Dal Negro, T. (2004). Prediction of nickel-base superalloys' rheological behaviour under hot forging conditions using artificial neural networks. *Journal of Materials Processing Technology*, 152(3), 395-400. <https://doi.org/https://doi.org/10.1016/j.jmatprotec.2004.04.416>
- Basilico, E., & Johnsen, T. (2019). Index Investing: It Makes Active Management Better. *Smart (er) Investing* (ss. 19-35). Springer. [https://doi.org/10.1007/978-3-030-26692-9\\_3](https://doi.org/10.1007/978-3-030-26692-9_3)
- Belman-Flores, J. M., Ledesma, S., Barroso-Maldonado, J. M., & Navarro-Esbrí, J. (2015). A comparison between the modeling of a reciprocating compressor using artificial neural network and physical model. *International Journal of Refrigeration*, 59, 144-156. <https://doi.org/10.1016/j.ijrefrig.2015.07.017>
- Ben Belgacem, S., & Hellara, S. (2011). Predicting Tunisian mutual fund performance using dynamic panel data model. *The Journal of Risk Finance*, 12(3), 208-225. <https://doi.org/10.1108/15265941111136950>
- Ber, S., Kempf, A., & Ruenzi, S. (2007). The German mutual fund market. G. N. Gregoriou (Ed.), *Performance of Mutual Funds* (ss. 210-229). Palgrave Macmillan.
- Bierman Jr, H., & Smidt, S. (2007). *Advanced capital budgeting: Refinements in the economic analysis of investment projects*. Routledge.
- Birdthistle, W. A. (2016). *Empire of the Fund: The Way We Save Now*. Oxford University Press.
- Bogle, J. C. (2015). *Bogle on mutual funds: New perspectives for the intelligent investor*. John Wiley & Sons.
- Bouveret, A., & Ju, Y. (2021). *Risks and Vulnerabilities in the U.S. Bond Mutual Fund Industry* 109). I. M. Fund.
- Cabaneros, S. M., Calautit, J. K., & Hughes, B. R. (2019). A review of artificial neural network models for ambient air pollution prediction. *Environmental Modelling & Software*, 119, 285-304. <https://doi.org/10.1016/j.envsoft.2019.06.014>
- Cai, S., Bileschi, S., Nielsen, E. D., & Chollet, F. (2020). *Deep Learning with JavaScript: Neural Networks in Tensorflow.js*. Manning Publications Co.
- Calverley, J. P., Meder, A. M., Singer, B. D., & Staub, R. (2007). Capital Market Expectations. J. L. Maginn, D. L. Tuttle, D. W. McLeavey, & J. E. Pinto (Eds.), *Managing Investment Portfolios: A Dynamic Process* (3 ed., ss. 128-229). John Wiley & Sons.
- Cerinski, D., Baleta, J., Mikulčić, H., Mikulandrić, R., & Wang, J. (2020). Dynamic modelling of the biomass gasification process in a fixed bed reactor by using the artificial neural network. *Cleaner Engineering and Technology*, 1, 100029. <https://doi.org/10.1016/j.clet.2020.100029>

- Chanda, B., Jana, P. P., & Das, J. (2021). A tool to predict the evolution of phase and Young's modulus in high entropy alloys using artificial neural network. *Computational Materials Science*, 197, 110619. <https://doi.org/https://doi.org/10.1016/j.commatsci.2021.110619>
- Chattopadhyay, R. (2011). Artificial neural networks in yarn property modeling. A. Majumdar (Ed.), *Soft Computing in Textile Engineering* (ss. 105-125). Woodhead Publishing Limited.
- Chevalier, J., & Ellison, G. (1999). Are some mutual fund managers better than others? Cross-sectional patterns in behavior and performance. *The journal of finance*, 54(3), 875-899.
- Chiang, W. C., Urban, T. L., & Baldrige, G. W. (1996). A neural network approach to mutual fund net asset value forecasting. *Omega*, 24(2), 205-215. [https://doi.org/https://doi.org/10.1016/0305-0483\(95\)00059-3](https://doi.org/https://doi.org/10.1016/0305-0483(95)00059-3)
- Ciaburro, G., Iannace, G., Ali, M., Alabdulkarem, A., & Nuhait, A. (2020). An Artificial neural network approach to modelling absorbent asphalts acoustic properties. *Journal of King Saud University-Engineering Sciences*. <https://doi.org/10.1016/j.jksues.2020.07.002>
- Cui, X., Kær, S. K., & Nielsen, M. P. (2022). Energy analysis and surrogate modeling for the green methanol production under dynamic operating conditions. *Fuel*, 307, 121924. <https://doi.org/https://doi.org/10.1016/j.fuel.2021.121924>
- Çağlayan Akay, E. (2020). *Ekonometride Büyük Veri ve Makine Öğrenmesi: Temel Kavramlar*. Der Yayınları.
- Çalışkan Çavdar, Ş., & Aydın, A. D. (2018). *Finans Alanında Yapay Zeka ve Ekonometrik Uygulamalar*. Seçkin Yayıncılık.
- da Silva, I. N., Hernane Spatti, D., Andrade Flauzino, R., Liboni, L. H. B., & dos Reis Alves, S. F. (2017). Artificial Neural Network Architectures and Training Processes. *Artificial Neural Networks : A Practical Course* (ss. 21-28). Springer International Publishing. [https://doi.org/10.1007/978-3-319-43162-8\\_2](https://doi.org/10.1007/978-3-319-43162-8_2)
- da Silva, I. N., Hernane Spatti, D., Andrade Flauzino, R., Liboni, L. H. B., & dos Reis Alves, S. F. (2018). *Artificial neural networks: a practical course*. Springer. <https://doi.org/10.1007/978-3-319-43162-8>
- da Silva, L. E., & Coury, D. V. (2020). Network traffic prediction for detecting DDoS attacks in IEC 61850 communication networks. *Computers & Electrical Engineering*, 87, 106793. <https://doi.org/https://doi.org/10.1016/j.compeleceng.2020.106793>
- Damodaran, A. (2006). *Damodaran on valuation: security analysis for investment and corporate finance* (2.baskı). John Wiley & Sons.
- Delgado, J. M. P. Q., Silva, F. A. N., Azevedo, A. C., Silva, D. F., Campello, R. L. B., & Santos, R. L. (2020). Artificial neural networks to assess the useful life of reinforced concrete elements deteriorated by accelerated chloride tests. *Journal of Building Engineering*, 31, 101445. <https://doi.org/10.1016/j.jobe.2020.101445>
- Demuth, H., & Beale, M. (2004). *Neural Network Toolbox for Use with MATLAB: User's Guide; Computation, Visualization, Programming*. MathWorks Incorporated.
- Desouky, M. A. A., & Abdelkhalik, O. (2019). Wave prediction using wave rider position measurements and NARX network in wave energy conversion. *Applied Ocean Research*, 82, 10-21. <https://doi.org/10.1016/j.apor.2018.10.016>

- Di Nunno, F., & Granata, F. (2020). Groundwater level prediction in Apulia region (Southern Italy) using NARX neural network. *Environmental Research*, 190, 110062. <https://doi.org/https://doi.org/10.1016/j.envres.2020.110062>
- Doğanay, M. (2002). Hisse Senedi Fonlarının Çok Kriterli Karar Yaklaşımı ile Derecelendirilmesi. *Ankara Üniversitesi SBF Dergisi*, 57(3), 31-48.
- Downes, J., & Goodman, J. E. (2003). *Barron's finance & investment handbook*. Barron's Educational Series.
- Ebrahimzadeh, A., Ghafari, M., & Moshkbar-Bakhshayesh, K. (2022). Detection and estimation of faulty sensors in NPPs based on thermal-hydraulic simulation and feed-forward neural network. *Annals of Nuclear Energy*, 166, 108726. <https://doi.org/https://doi.org/10.1016/j.anucene.2021.108726>
- Elmesseary, M. (2014). Actively Managed Investment Portfolio Dilemmas, 'Lost Returns Approach'. *European Journal of Sustainable Development*, 3(3), 263-274. <https://doi.org/10.14207/ejsd.2014.v3n3p263>
- Ergün, B. (2020). *Uluslararası Portföy Çeşitlendirmesi*. Gazi Kitabevi.
- Ertaylan, A., Aktaş, Ö., & Doğan, Y. (2021). Yapay Sinir Ağları ile Piyasa Takas Fiyatı Tahminlemesi. *Dokuz Eylül Üniversitesi Mühendislik Fakültesi Fen ve Mühendislik Dergisi*, 23(67), 93-105. <https://doi.org/10.21205/deufmd.2021236708>
- Fabozzi, F. J. (2009). *Institutional investment management: Equity and bond portfolio strategies and applications*. John Wiley & Sons.
- Fabozzi, F. J., Markowitz, H. M., & Gupta, F. (2008). Portfolio Selection. F. J. Fabozzi (Ed.), *Handbook of Finance* (Vol. 2, ss. 3-13). John Wiley & Sons. <https://doi.org/https://doi.org/10.1002/9780470404324.hof002001>
- Fibaportföy. (2021). *Yatırım fonlarında dikkat edilmesi gereken konular*. 25.09.2021 tarihinde <http://www.fibaportfoy.com.tr/YatirimFonlarindaDikkatEdilmesiGereken> adresinden erişildi.
- Finnet. (2021). *Analiz Expert Nedir?* 11.01.2021 tarihinde <https://www.finnet.com.tr/FinnetStore/Tr/Urun/AnalizExpert> adresinden erişildi.
- Fırat, Y. (2020). Application of the Air Quality Forecasting Analysis Using NARX Models. *Gümüşhane Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, 10(2), 442-455. <https://doi.org/10.17714/gumusfenbil.605649>
- Frahm, G., & Huber, F. (2019). The outperformance probability of mutual funds. *Journal of Risk and Financial Management*, 12(3), 108. <https://doi.org/10.3390/jrfm12030108>
- Gabbi, G. (2007). International Mutual Fund Efficiency and Monetary Policy Sensitivity. G. N. Gregoriou (Ed.), *Diversification and Portfolio Management of Mutual Funds* (ss. 78-93). Palgrave Macmillan.
- Gerber, M. (2008). *How to Create and Manage a Mutual Fund or Exchange-Traded Fund*. John Wiley & Sons.
- Grinold, R. C., & Kahn, R. N. (2019). *Advances in Active Portfolio Management: New Developments in Quantitative Investing*. McGraw Hill Professional.
- Guidolin, M., & Pedio, M. (2016). *Essentials of applied portfolio management*. EGEA spa.
- Güleryüz, D., & Özden, E. (2020). Büyük Veri ile Gelen Değişim: Finans Sektöründe Yapay Zeka. Ü. Gülhan & A. Ağ (Eds.), *Finans Alanında Spesifik Konular* (ss. 155-172). Gazi Kitabevi.



- Günay, S. G. (2019). *Finansal Yönetimin İlkeleri (SPK Sınavı Çözümlü Sorular)*. Gazi Kitabevi.
- Gündoğdu, A. (2018). *Sermaye Piyasası Hukuku* (3.baskı). Seçkin Yayıncılık.
- Gürsoy, C. T. (2007). *Finansal Yönetim İlkeleri*. Doğu Üniversitesi Yayınları.
- Güven, İ., & Şimşir, F. (2020). Demand forecasting with color parameter in retail apparel industry using artificial neural networks (ANN) and support vector machines (SVM) methods. *Computers & Industrial Engineering*, *147*, 106678. <https://doi.org/10.1016/j.cie.2020.106678>
- Han-Sen, L., Mei-Ling, C., Chia-Chang, T., & Jiang-Whai, D. (2007, 18-20 Nov. 2007). Using grey and RBFNN to predict the net asset value of single nation equity funds-a case study of Taiwan, US, and Japan. 2007 IEEE International Conference on Grey Systems and Intelligent Services,
- Haslem, J. A. (2003). *Mutual funds: risk and performance analysis for decision making*. Blackwell Publishing.
- Haslem, J. A. (2010). *Mutual Funds: Portfolio structures, analysis, management, and stewardship*. John Wiley & Sons.
- Hassan, H., Ahmed, I., Ahmad, R., Khammari, H., Bhatti, G., Ahmed, W., & Alam, M. M. (2019). A Machine Learning Approach to Achieving Energy Efficiency in Relay-Assisted LTE-A Downlink System. *Sensors*, *19*(16), 3461. <https://www.mdpi.com/1424-8220/19/16/3461>
- Hassan, M. A., Bailek, N., Bouchouicha, K., & Nwokolo, S. C. (2021). Ultra-short-term exogenous forecasting of photovoltaic power production using genetically optimized non-linear auto-regressive recurrent neural networks. *Renewable Energy*, *171*, 191-209. <https://doi.org/https://doi.org/10.1016/j.renene.2021.02.103>
- Haykin, S. (2009). *Neural networks and learning machines* (3.baskı). Prentice Hall.
- Hiriyappa, B. (2008). *Investment management: Securities and portfolio management*. New Age International (P) Limited, Publishers.
- Hongcheng, Y., Wenyi, L., Xiuying, L., Huihua, K., & Chufu, L. (2010, 22-24 Oct. 2010). Predicting net asset value of investment fund based on BP neural network. 2010 International Conference on Computer Application and System Modeling (ICCASM 2010),
- Hota, S., Jena, S. K., Gupta, B. K., & Mishra, D. (2021a). An Empirical Comparative Analysis of NAV Forecasting Using Machine Learning Techniques. In D. Mishra, R. Buyya, P. Mohapatra, & S. Patnaik, *Intelligent and Cloud Computing* Singapore.
- Hota, S., Kuhoo, Mishra, D., & Patnaik, S. (2020). An empirical net asset value forecasting model based on optimised ANN using elephant herding strategy. *International Journal of Management and Decision Making*, *19*(1), 118-132. <https://doi.org/10.1504/ijmdm.2020.104183>
- Hota, S., Pati, S. P., Mishra, D., & Satapathy, P. (2018, 21-23 Sept. 2018). Net Asset Value Prediction Using Extreme Learning Machine with Dolphin Swarm Algorithm. 2018 2nd International Conference on Data Science and Business Analytics (ICDSBA),
- Hota, S., Pati, S. P., & Satapathy, P. (2021b). Forecasting of Net Asset Value of Indian Mutual Funds Using Firefly Algorithm-Based Neural Network Model. In R. Sharma, M. Mishra, J. Nayak, B. Naik, & D. Pelusi, *Green Technology for Smart City and Society* Singapore.



- HSBC. (2021). *HSBC Portföy Değişken Fon*. 12.01.2021 tarihinde <http://www.hsbcportfoy.com.tr/yatirim-fonlari/yatirim-fonlari/hsbc-portfoy-degisken-fon> adresinden erişildi.
- Huang, G.-B. (2003). Learning capability and storage capacity of two-hidden-layer feedforward networks. *IEEE Transactions on Neural Networks*, 14(2), 274-281. <https://doi.org/10.1109/TNN.2003.809401>
- Huang, T. H., & Leu, Y. H. (2014). A mutual fund investment method using fruit fly optimization algorithm and neural network. *Applied Mechanics and Materials*, 571-572, 318-325. <https://doi.org/10.4028/www.scientific.net/AMM.571-572.318>
- İltir, C. (2018). *Excel'de Finans Uygulamaları* (2.baskı). Seçkin Yayıncılık.
- Inci, A. C., Saraoglu, H. J. E. M. F., & Trade. (2011). International equity asset classes in the Turkish fund industry. *Emerging Markets Finance and Trade*, 47(4), 96-114. <https://doi.org/10.2753/REE1540-496X470406>
- İstanbulPortföy. (2021). *Yatırım Fonlarımız*. 26.09.2021 tarihinde <http://www.istanbulportfoy.com/services/funds/index.html> adresinden erişildi.
- İşportföy. (2021). *Yatırım fonları genel bilgiler*. 25.09.2021 tarihinde <https://www.isportfoy.com.tr/tr/yatirim-fonlari-genel-bilgiler> adresinden erişildi.
- Iverson, D. (2013). *Strategic Risk Management: A Practical Guide to Portfolio Risk Management*. John Wiley & Sons.
- Jebamalar, S., Christopher, J. J., & Ajisha, M. A. T. (2020). Random input based prediction and transfer of heat in soil temperature using artificial neural network. *Materials Today: Proceedings*. <https://doi.org/10.1016/j.matpr.2020.08.091>
- Jiang, H., Xi, Z., Rahman, A. A., & Zhang, X. (2020a). Prediction of output power with artificial neural network using extended datasets for stirling engines. *Applied Energy*, 271, 115123. <https://doi.org/10.1016/j.apenergy.2020.115123>
- Jiang, Y., Yang, N., Yao, Q., Wu, Z., & Jin, W. (2020b). Real-time moisture control in sintering process using offline–online NARX neural networks. *Neurocomputing*, 396, 209-215. <https://doi.org/10.1016/j.neucom.2018.07.099>
- Jones, C. P. (2013). *Investments: analysis and management* (12.baskı). John Wiley & Sons.
- Jung, D.-H., Kim, H. S., Jhin, C., Kim, H.-J., & Park, S. H. (2020). Time-serial analysis of deep neural network models for prediction of climatic conditions inside a greenhouse. *Computers and Electronics in Agriculture*, 173, 105402. <https://doi.org/https://doi.org/10.1016/j.compag.2020.105402>
- Kalantary, S., Jahani, A., & Jahani, R. (2020). MLR and ANN Approaches for Prediction of Synthetic/Natural Nanofibers Diameter in the Environmental and Medical Applications. *Scientific Reports*, 10(1), 8117. <https://doi.org/10.1038/s41598-020-65121-x>
- Kamu-Gözetimi-Kurumu. (2020). Bağımsız denetim standardı 200. In *Bağımsız denetçinin genel amaçları ve bağımsız denetimin bağımsız denetim standartlarına uygun olarak yürütülmesi* (ss. 32).
- Kandziolka, C. (2012). *Personal Wealth Management and Retirement*. Charles Kandziolka. <https://books.google.com.tr/books?id=HokBBAAAQBAJ>
- KAP. (2021). *Fon Sürekli Bilgilendirme Formu*. 26.09.2021 tarihinde <https://www.kap.org.tr/tr/Bildirim/963629> adresinden erişildi.
- KAP. (2022). *Yatırımcı Bilgi Formu*. 02.07.2022 tarihinde <https://www.kap.org.tr/ek-indir/4028328c80292449018041cbc80766b8> adresinden erişildi.

- Karan, M. B. (2020). *Yatırım Analizi ve Portföy Yönetimi* (6.baskı). Gazi Kitabevi.
- Kashani, H. R. K., Azhari, S., Nayebaghayee, H., Salimi, S., & Mohammadi, H. R. (2020). Prediction value of preoperative findings on meningioma grading using artificial neural network. *Clinical Neurology Neurosurgery*, 196, 105947. <https://doi.org/10.1016/j.clineuro.2020.105947>
- Ke, J., & Liu, X. (2008, December 19–20, 2008). Empirical analysis of optimal hidden neurons in neural network modeling for stock prediction. 2008 IEEE Pacific-Asia Workshop on Computational Intelligence and Industrial Application, Wuhan, China.
- Khaleghi, S., Karimi, D., Beheshti, S. H., Hosen, M. S., Behi, H., Berecibar, M., & Van Mierlo, J. (2021). Online health diagnosis of lithium-ion batteries based on nonlinear autoregressive neural network. *Applied Energy*, 282, 116159. <https://doi.org/https://doi.org/10.1016/j.apenergy.2020.116159>
- Kim, J.-H., Kim, Y., & Lu, W. (2020a). Prediction of ice resistance for ice-going ships in level ice using artificial neural network technique. *Ocean Engineering*, 217, 108031. <https://doi.org/10.1016/j.oceaneng.2020.108031>
- Kim, M. K., Kim, Y.-S., & Srebric, J. (2020b). Impact of correlation of plug load data, occupancy rates and local weather conditions on electricity consumption in a building using four back-propagation neural network models. *Sustainable Cities and Society*, 62, 102321. <https://doi.org/https://doi.org/10.1016/j.scs.2020.102321>
- Kıyılar, M., & Akkaya, M. (2020). *Davranışsal Finans* (2.baskı). Literatür Yayıncılık.
- Kjelle, M. M. (2014). *A teen guide to mutual funds*. Mitchell Lane Publishers.
- Koç, İ. Ö. (2011). *Portföy Yönetimi ve Sigortacılık Sektörü*. Yalın Yayıncılık.
- Korkmaz, T., & Uygurtürk, H. (2007a). Türk Emeklilik Fonlarının Performans Ölçümünde Regresyon Analizinin Kullanılması. *Uluslararası Yönetim İktisat ve İşletme Dergisi*, 3(5), 37-52.
- Korkmaz, T., & Uygurtürk, H. (2007b). Türkiye'deki emeklilik fonlarının performans ölçümü ve fon yöneticilerinin zamanlama yeteneği. *Akdeniz İİBF Dergisi*, 7(14), 66-93.
- Korkmaz, T., & Uygurtürk, H. (2008). Türkiye'deki emeklilik fonları ile yatırım fonlarının performans karşılaştırması ve fon yöneticilerinin zamanlama yetenekleri. *Kocaeli Üniversitesi Sosyal Bilimler Dergisi*(15), 114-147.
- Koudjonou, K. M., & Rout, M. (2020). A stateless deep learning framework to predict net asset value. *Neural Computing and Applications*, 32(14), 1-19. <https://doi.org/10.1007/s00521-019-04525-x>
- Koul, S. (2021). Machine learning and deep learning in agriculture. G. S. Patel, A. Rai, N. N. Das, & R. P. Singh (Eds.), *Smart Agriculture: Emerging Pedagogies of Deep Learning, Machine Learning and Internet of Things* (ss. 1-19). CRC Press. <https://doi.org/10.1201/b22627>
- Kumar, N., & Makkar, A. (2020). *Machine learning in cognitive IoT*. CRC Press.
- Kumar, R. (2014). *Strategies of banks and other financial institutions: Theories and cases*. Elsevier.
- Kurt, M. (2017). *Development of an Offshore Specific Wind Power Forecasting System*. kassel university press GmbH. <https://doi.org/10.19211/KUP9783737603478>
- Kurtaran, A. T., & Kurtaran, A. (2010). Türkiye'de emeklilik yatırım fonlarının performans değerlendirmesi. *Dumlupınar Üniversitesi Sosyal Bilimler Dergisi*, 2(26), 248 - 259.

- Latko, D. W. (2003). *Financial Strategies for Today's Widow: Coping with the Economic Challenges of Losing a Spouse*. Fireside.
- Le Sourd, V. (2007). *Return-based style analysis: An answer to the difficulties of implementing holding-based style analysis*. 27.09.2021 tarihinde <https://risk.edhec.edu/> adresinden erişildi.
- Loader, D. (2007). *Fundamentals of fund administration: a guide*. Elsevier.
- Louzazni, M., Mosalam, H., Khouya, A., & Amechnoue, K. (2020). A non-linear auto-regressive exogenous method to forecast the photovoltaic power output. *Sustainable Energy Technologies and Assessments*, 38, 100670. <https://doi.org/https://doi.org/10.1016/j.seta.2020.100670>
- Lu, R.-S., Yu, S.-W., & Lin, Y.-H. (2008, 1-8 June 2008). The prediction of applying Smooth Support Vector Regression and Back Propagation Network in mutual fund performance. 2008 IEEE International Joint Conference on Neural Networks (IEEE World Congress on Computational Intelligence),
- Lungu, I., Bara, A., Carutasu, G., Pirjan, A., & Oprea, S.-V. (2016). Prediction Intelligent System In The Field Of Renewable Energies Through Neural Networks. *Economic Computation and economic cybernetics studies and research*, 50(1), 85-102.
- Lustig, Y. (2013). *Multi-asset Investing: A Practical Guide to Modern Portfolio Management*. Harriman House Limited.
- Lückoff, P. (2011). *Mutual Fund Performance and Performance Persistence: The impact of fund flows and manager changes*. Gabler Verlag.
- Maginn, J. L., Tuttle, D. L., McLeavey, D. W., & Pinto, J. E. (2007). The portfolio management process and the investment policy statement. J. L. Maginn, D. L. Tuttle, D. W. McLeavey, & J. E. Pinto (Eds.), *Managing investment portfolios: A dynamic process* (3 ed., ss. 1-19). John Wiley & Sons.
- Mahdaviara, M., Larestani, A., Nait Amar, M., & Hemmati-Sarapardeh, A. (2022). On the evaluation of permeability of heterogeneous carbonate reservoirs using rigorous data-driven techniques. *Journal of Petroleum Science and Engineering*, 208, 109685. <https://doi.org/https://doi.org/10.1016/j.petrol.2021.109685>
- Majhi, B., Anish, C. M., & Majhi, R. (2021). On development of novel hybrid and robust adaptive models for net asset value prediction. *Journal of King Saud University - Computer and Information Sciences*, 33(6), 647-657. <https://doi.org/https://doi.org/10.1016/j.jksuci.2018.04.011>
- Martins, F. G., Gonçalves, D. J. D., & Peres, J. (2011). Artificial Neural Networks in Environmental Sciences and Chemical Engineering. J. A. Flores (Ed.), *Focus on Artificial Neural Networks* (ss. 55-74). Nova Science Publishers.
- Mattig, A. (2009). *Industrial dynamics and the evolution of markets in the mutual Fund industry*. Gabler.
- Matzenberger, J. (2013). Neuronal Network Based Modelling of Demand and Competing use of Forestry Commodities for Material and Energy use. *Energy Procedia*, 40, 156-164. <https://doi.org/https://doi.org/10.1016/j.egypro.2013.08.019>
- Mavaddat, N., Ahderom, S., Tiporlini, V., & Alameh, K. (2020). Simulation of biomedical signals and images using Monte Carlo methods for training of deep learning networks. B. Agarwal, V. E. Balas, L. C. Jain, R. C. Poonia, & Manisha (Eds.), *Deep Learning Techniques for Biomedical and Health Informatics* (ss. 213-236). Elsevier. <https://doi.org/10.1016/B978-0-12-819061-6.00009-4>

- May, R., Dandy, G., & Maier, H. (2011). Review of input variable selection methods for artificial neural networks. In K. Suzuki (Ed.), *Artificial neural networks-methodological advances and biomedical applications* (ss. 19-44). InTech. <https://doi.org/10.5772/16004>
- Meesaraganda, L. P., Saha, P., & Tarafder, N. (2019). Artificial Neural Network for Strength Prediction of Fibers' Self-compacting Concrete. J. C. Bansal, K. N. Das, A. Nagar, K. Deep, & A. K. Ojha (Eds.), *Soft Computing for Problem Solving* (Vol. 1, ss. 15-24). Springer. [https://doi.org/10.1007/978-981-13-1592-3\\_2](https://doi.org/10.1007/978-981-13-1592-3_2)
- Melgar, M. P., & Rodriguez Vazquez, V. P. (2009). *Como Listar En El G8?* AuthorHouse.
- Metin, N., Karadağ, K., & Terzioğlu, M. K. (2020). MLP/RBF Ağ Mimarileriyle Hibrit MGARCH-ANN Model Performans Karşılaştırması: Petrol Fiyat Oynaklığı. *Ankara Hacı Bayram Veli Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*(Özel Sayı), 78-93.
- Yatırım Fonlarına İlişkin Esaslar Tebliği (III-52.1), (2012). <https://www.mevzuat.gov.tr/File/GeneratePdf?mevzuatNo=18564&mevzuatTur=Tebliğ&mevzuatTertip=5>
- Milan, P. L. A. B., & Junior, W. E. (2015). Determinants of portfolio turnover for equity mutual funds. *Brazilian Business Review*, 12(5), 1-15. <https://doi.org/10.15728/bbr.2015.12.5.1>
- Mirabile, K. R. (2016). *Hedge fund investing: A practical approach to understanding investor motivation, manager profits, and fund performance* (2.baskı). John Wiley & Sons.
- Mitchell, B. R. (2021). Overview of advanced neural network architectures. S. Cohen (Ed.), *Artificial Intelligence and Deep Learning in Pathology* (ss. 41-56). Elsevier. <https://doi.org/10.1016/B978-0-323-67538-3.00003-8>
- Mitrofanov, A., Parsheva, K., & Nosenko, V. (2020). Simulation of an artificial neural network for predicting temperature and cutting force during grinding using CAMQL. *Materials Today: Proceedings*. <https://doi.org/10.1016/j.matpr.2020.08.139>
- Mittal, S., & Hasija, Y. (2020). Applications of deep learning in healthcare and biomedicine. S. Dash, B. R. Acharya, M. Mittal, A. Abraham, & A. Kelemen (Eds.), *Deep Learning Techniques for Biomedical and Health Informatics* (ss. 57-77). Springer. [https://doi.org/10.1007/978-3-030-33966-1\\_4](https://doi.org/10.1007/978-3-030-33966-1_4)
- Mobius, M. (2007). *Mutual funds: An introduction to the core concepts*. John Wiley & Sons.
- Mohanty, S., & Dash, R. (2021). Application of Computational Intelligence Techniques in the Domain of Net Asset Value Prediction: A Survey. In D. Mishra, R. Buyya, P. Mohapatra, & S. Patnaik, *Intelligent and Cloud Computing* Singapore.
- Muravyova, E., & Gabitov, R. (2021). Development of the intellectual complex for parallel work of steam boilers. *Journal of Physics: Conference Series*, 1889(2021), 022047.
- Mustapa, R. F., Dahlan, N. Y., Yassin, A. I. M., & Nordin, A. H. M. (2020). Quantification of energy savings from an awareness program using NARX-ANN in an educational building. *Energy and Buildings*, 215, 109899. <https://doi.org/10.1016/j.enbuild.2020.109899>
- Münyas, T. (2018). *Finansal Yönetim ve Portföy Yönetim Teorisi*. Seçkin Yayıncılık.



- Nabiyev, V. V. (2016). *Yapay Zeka: Stratejili Oyunlar - Örüntü Tanıma - Doğal Dil İşleme* (5.baskı). Seçkin Yayıncılık.
- Narula, A., Jha, C. B., & Panda, G. (2015). Development and performance evaluation of three novel prediction models for mutual fund NAV prediction. *Ann Res J Symbiosis Centre Manag Stud*, 3, 227-238.
- Negash, B. M., & Yaw, A. D. (2020). Artificial neural network based production forecasting for a hydrocarbon reservoir under water injection. *Petroleum Exploration and Development*, 47(2), 383-392. [https://doi.org/https://doi.org/10.1016/S1876-3804\(20\)60055-6](https://doi.org/https://doi.org/10.1016/S1876-3804(20)60055-6)
- Oktayer, N., & Oktayer, A. (2007). Özel emeklilik fonlarının finansal piyasaların gelişimine etkileri. *Afyon Kocatepe Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 9(2), 55 - 80.
- Orçun, Ç. (2016a). *Bireysel Yatırımcı Ne İster? Finansal Risk Algısı Üzerine Bir Araştırma*. Ekin Yayınevi.
- Orçun, Ç. (2016b). Uluslararası portföy yatırımları. S. Güler & N. Kayalı (Eds.), *Ekonomi ve işletme biliminde yatırım* (ss. 87-106). Ekin Yayınevi.
- Orkunoğlu Şahin, I. F. (2022). Türkiye'nin 1980-2021 Dönemi Dış Ticaret Gelişiminin İrdelenmesi. *Gümrük ve Ticaret Dergisi*, 9(27), 82-99.
- Özarslan, Ö. S. (2018). Modern Portföy Teorisi. T. Münyas (Ed.), *Finansal Yönetim ve Portföy Yönetim Teorisi* (ss. 351-385). Seçkin Yayıncılık.
- Özçelik, Ö., & Göksu, S. (2020). CDS primleri ve enflasyon oranının, faiz oranlarına etkisi: Türkiye Örneği. *Aksaray Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 12(1), 69-78.
- Öztürkkal, B. (2011). *Finans, Hayat, Vesaire...* Literatür Yayıncılık.
- Parameswaran, S. K. (2010). *Mutual Funds and Retirement Planning*. Tata McGraw Hill Education.
- Paturi, U. M. R., & Cheruku, S. (2020). Application and performance of machine learning techniques in manufacturing sector from the past two decades: A review. *Materials Today: Proceedings*, 1-10. <https://doi.org/10.1016/j.matpr.2020.07.209>
- Pendaraki, K. N., & Tsagarakis, K. P. (2016). Linear Regression Versus Fuzzy Linear Regression: Does it Make a Difference in the Evaluation of the Performance of Mutual Fund Managers? C. L. Dunis, P. W. Middleton, A. Karathanasopoulos, & K. Theofilatos (Eds.), *Artificial Intelligence in Financial Markets* (ss. 311-335). Palgrave Macmillan. [https://doi.org/10.1057/978-1-137-48880-0\\_11](https://doi.org/10.1057/978-1-137-48880-0_11)
- Pfeiferová, D., & Kuchařová, I. (2020). Risks of collective investment undertakings in the context of global capital markets. SHS Web of Conferences,
- Pozen, R., & Hamacher, T. (2015). *The fund industry: How your money is managed* (2.baskı). John Wiley & Sons.
- Priyadarshini, E. (2015). A comparative analysis of prediction using Artificial Neural network and auto regressive integrated moving average. *ARPN Journal of Engineering and Applied Sciences*, 10(7), 3078-3081.
- Priyadarshini, E., & Babu, A. C. (2012). A Comparative Analysis for Forecasting the NAV's of Indian Mutual Fund using Multiple Regression Analysis and Artificial Neural Networks. *International Journal of Trade, Economics and Finance*, 3(5), 347.
- Promptsook, N., & Waiyamai, K. (2021, 26-27 Aug. 2021). Thai Equity Mutual Fund Net Asset Value Return Prediction Using Internal Factors. 2021 2nd International Conference on Big Data Analytics and Practices (IBDAP),

- Quinto, B. (2020). *Next-Generation Machine Learning with Spark: Covers XGBoost, LightGBM, Spark NLP, Distributed Deep Learning with Keras, and More*. Apress Media LLC. <https://doi.org/10.1007/978-1-4842-5669-5>
- Rabiej, M., & Rabiej, S. (2021). Application of the artificial neural network for identification of polymers based on their X-ray diffraction curves. *Computational Materials Science*, 186, 110042. <https://doi.org/10.1016/j.commatsci.2020.110042>
- Rachmawati, R., Wahyudi, S., & Pangestuti, I. R. D. (2020). Funds Manager and Mutual Funds Characteristics on Mutual Funds Performance: Empirical Evidence of Equity Mutual Funds in Indonesia. *International Journal of Financial Research*, 11(2), 77-87. <https://doi.org/10.5430/ijfr.v11n2p77>
- Rahimi, Z., Mohd Shafri, H. Z., & Norman, M. (2018). A GNSS-based weather forecasting approach using Nonlinear Auto Regressive Approach with Exogenous Input (NARX). *Journal of Atmospheric and Solar-Terrestrial Physics*, 178, 74-84. <https://doi.org/https://doi.org/10.1016/j.jastp.2018.06.011>
- Ranganatham, M., & Madhumathi, R. (2006). *Investment analysis and portfolio management*. Dorling Kindersley (India).
- Rani, I. J., & Chandar, S. K. (2018). A Study on Forecasting Mutual Fund Net Asset Value Using Neural Network Approach. *International Journal on Future Revolution in Computer Science & Communication Engineering*, 4(3), 89-93.
- Rawat, V., Jain, A., Shrimali, V., & Raghuvanshi, S. (2018). Performance Analysis of Different Learning Algorithms of Feed Forward Neural Network Regarding Fetal Abnormality Detection. N. Thanh Nguyen & R. Kowalczyk (Eds.), *Transactions on Computational Collective Intelligence XXX* (ss. 118-132). Springer International Publishing. [https://doi.org/10.1007/978-3-319-99810-7\\_6](https://doi.org/10.1007/978-3-319-99810-7_6)
- Ray, P., & Vina, V. (2004). Neural network models for forecasting mutual fund net asset value. 8th capital markets conference, Indian Institute of Capital Markets Paper,
- Reilly, F. K., Brown, K. C., Hedges, P. L., & Chang, P. C. (2010). *Investment Analysis and Portfolio Management (Text Only)*. Nelson Education.
- Rençber, Ö. F. (2018). *Sınıflandırma Problemlerinde Çoklu Lojistik Regresyon, Yapay Sinir Ağı ve ANFIS Yöntemlerinin Karşılaştırılması: İnsani Gelişmişlik Endeksi Üzerine Uygulama*. Gazi Kitabevi.
- Roghanchi, P., & Kocsis, K. C. (2019). Quantifying the thermal damping effect in underground vertical shafts using the nonlinear autoregressive with external input (NARX) algorithm. *International Journal of Mining Science and Technology*, 29(2), 255-262. <https://doi.org/https://doi.org/10.1016/j.ijmst.2018.06.002>
- Rosa, J. P., Guerra, D. J., Horta, N. C., Martins, R. M., & Lourenço, N. C. (2019). Overview of Artificial Neural Networks. *Using Artificial Neural Networks for Analog Integrated Circuit Design Automation* (ss. 21-44). Springer. [https://doi.org/10.1007/978-3-030-35743-6\\_3](https://doi.org/10.1007/978-3-030-35743-6_3)
- Russell, R. (2007). *An introduction to mutual funds worldwide*. John Wiley & Sons.
- Saha, J., Chowdhury, C., & Biswas, S. (2020). Review of machine learning and deep learning based recommender systems for health informatics. S. Dash, B. R. Acharya, M. Mittal, A. Abraham, & A. Kelemen (Eds.), *Deep Learning Techniques for Biomedical and Health Informatics* (ss. 101-126). Springer. [https://doi.org/10.1007/978-3-030-33966-1\\_6](https://doi.org/10.1007/978-3-030-33966-1_6)
- Salo, A., Keisler, J., & Morton, A. (2011). An invitation to portfolio decision analysis. A. Salo, J. Keisler, & A. Morton (Eds.), *Portfolio decision analysis: Improved*

- methods for resource allocation* (Vol. International Series in Operations Research & Management Science, ss. 3-27). Springer. [https://doi.org/10.1007/978-1-4419-9943-6\\_1](https://doi.org/10.1007/978-1-4419-9943-6_1)
- Santos, R., & Vianna, P. (2019). Coordenação de prazos e eficiência previdenciária. *Revista Brasileira de Economia*, 73, 121-135. <https://doi.org/10.5935/0034-7140.20190006>
- Sarıgül, H. (2019). *A'dan Z'ye Finansal Okuryazarlık*. Der Yayınları.
- Saxena, S., Paul, S., Garg, A., Saikia, A., & Datta, A. (2020). Deep Learning in Computational Neuroscience. R. Kashyap & A. V. S. Kumar (Eds.), *Challenges and Applications for Implementing Machine Learning in Computer Vision* (ss. 43-63). IGI Global. <https://doi.org/10.4018/978-1-7998-0182-5.ch002>
- Sayılgan, G. (2019). *Soru ve Yanıtlarıyla İşletme Finansmanı* (8.baskı). Siyasal Kitabevi.
- SEC. (2017). *PIMCO Emerging Markets Full Spectrum Bond Fund*. 14.01.2021 tarihinde adresinden erişildi.
- SEC. (2018). *Letter of instruction and notice to participants in the CSRA 401(K) plan*. 12.01.2021 tarihinde <https://www.sec.gov/Archives/edgar/data/40533/000119312518070495/d545926dex99a1c.htm> adresinden erişildi.
- Sekhar, G. S. (2017). *The Management of Mutual Funds*. Palgrave Macmillan. <https://doi.org/10.1007/978-3-319-34000-5>
- Senturk, U., Polat, K., & Yucedag, I. (2020). A non-invasive continuous cuffless blood pressure estimation using dynamic Recurrent Neural Networks. *Applied Acoustics*, 170, 107534. <https://doi.org/10.1016/j.apacoust.2020.107534>
- Shahbaz, M., Taqvi, S. A. A., Inayat, M., Inayat, A., Sulaiman, S. A., McKay, G., & Al-Ansari, T. (2020). Air catalytic biomass (PKS) gasification in a fixed-bed downdraft gasifier using waste bottom ash as catalyst with NARX neural network modelling. *Computers & Chemical Engineering*, 142, 107048. <https://doi.org/https://doi.org/10.1016/j.compchemeng.2020.107048>
- Sharifzadeh, M., Sikinioti-Lock, A., & Shah, N. (2019). Machine-learning methods for integrated renewable power generation: A comparative study of artificial neural networks, support vector regression, and Gaussian Process Regression. *Renewable and Sustainable Energy Reviews*, 108, 513-538. <https://doi.org/10.1016/j.rser.2019.03.040>
- Sharma, J. K. (2019). *Business Statistics* (5.baskı). Vikas Publishing. <https://books.google.com.tr/books?id=3B7zDwAAQBAJ>
- Shefrin, H. (2013). Asset Pricing and Behavioral Finance. H. K. Baker & G. Filbeck (Eds.), *Portfolio theory and management* (ss. 73-95). Oxford University Press.
- Silaparasetty, V. (2020). *Deep Learning Projects Using TensorFlow 2: Neural Network Development with Python and Keras*. Springer. <https://doi.org/10.1007/978-1-4842-5802-6>
- Simpson, T. D. (2014). *Financial markets, banking, and monetary policy*. John Wiley & Sons.
- Singh, P., & Manure, A. (2020). *Learn TensorFlow 2.0: Implement Machine Learning and Deep Learning Models with Python*. Apress Media LLC. <https://doi.org/10.1007/978-1-4842-5558-2>
- Soltangharaei, V., Anay, R., Assi, L., Bayat, M., Rose, J. R., & Ziehl, P. (2020). Analyzing acoustic emission data to identify cracking modes in cement paste

- using an artificial neural network. *Construction and Building Materials*, 121047. <https://doi.org/10.1016/j.conbuildmat.2020.121047>
- Spiegelhalter, D. J., Best, N. G., Carlin, B. P., & Van Der Linde, A. (2002). Bayesian measures of model complexity and fit. *Journal of the Royal Statistical Society: Series B (Statistical Methodology)*, 64(4), 583-639. <https://doi.org/https://doi.org/10.1111/1467-9868.00353>
- SPK. (2021). *Menkul Kıymet Yatırım Fonları Tanıtım Rehberi*. 27.09.2021 tarihinde <https://www.spk.gov.tr/Sayfa/AltSayfa/253> adresinden erişildi.
- St Giles, M., Alexeeva, E., & Buxton, S. (2003). *Managing collective investment funds* (2.baskı). John Wiley & Sons.
- Stankevičienė, J., & Petronienė, I. (2019). Bond Mutual Funds vs. Bond Exchange Traded Funds: Evaluation of Risk Adjusted Performance. *Administrative Sciences*, 9(2), 31. <https://www.mdpi.com/2076-3387/9/2/31>
- Stewart, S. D., Piros, C. D., & Heisler, J. C. (2019). *Portfolio Management: Theory and Practice*. John Wiley & Sons.
- Strong, R. A. (2008). *Portfolio construction, management, and protection* (5.baskı). South-Western Cengage Learning.
- Şahin, A., Cengiz, S., Bayrakdaroğlu, A., Gündoğdu, A., Özen, E., Taşkın Yeşilova, F. D., Selimler, H., Çelik, S., Ulusoy, T., Dayan, V., Koç, Y. D., Güzel, A., Erdoğan, A., Kubilay, B., Çağlı, E. Ç., Yeşildağ, E., Dayı, F., Göçmen Yağcılar, G., Tuncay, M., . . . Çimen, A. (2018). *Finansın Temel Kavramları: Güncel Örnekler ve Yaklaşımlar ile* (A. Gündoğdu, Ed.). Gazi Kitabevi.
- Takasbank. (2021). *Takasbank*. 05.03.2021 tarihinde <https://www.takasbank.com.tr/tr/hakkimizda/tanitim/takasbank> adresinden erişildi.
- TCMB. (2022a). *Tüketici Fiyatları*. 02.07.2022 tarihinde <https://www.tcmb.gov.tr/wps/wcm/connect/TR/TCMB+TR/Main+Menu/Istatistikler/Enflasyon+Verileri/Tuketici+Fiyatları> adresinden erişildi.
- TCMB. (2022b). *Üretici Fiyatları*. 02.07.2022 tarihinde <https://www.tcmb.gov.tr/wps/wcm/connect/TR/TCMB+TR/Main+Menu/Istatistikler/Enflasyon+Verileri/Üretici+Fiyatları> adresinden erişildi.
- TEFAS. (2021a). *Fon Bazlı İşlem Hacmi Raporu*. 05.09.2021 tarihinde <https://www.tefas.gov.tr/IstatistikRaporlar/Befas/FonBazliIslemHacmi.aspx> adresinden erişildi.
- TEFAS. (2021b). *Tarihsel Veriler*. 05.03.2021 tarihinde <https://www.tefas.gov.tr/TarihselVeriler.aspx> adresinden erişildi.
- TEFAS. (2021c). *Tefas Nedir?* 10.04.2021 tarihinde <https://www.tefas.gov.tr/> adresinden erişildi.
- Temizel, F., & Bayçelebi, B. B. (2016). Türkiye'deki yatırım fonlarının etkinliğe dayalı performans değerlemesi. *Aksaray Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 8(4), 11-31.
- Terzioğlu, M. K. (2018). *Riske Maruz Değer Kavram ve Uygulamalar*. Gazi Kitabevi.
- Thiyagarajan, P. (2020). A review on cyber security mechanisms using machine and deep learning algorithms. P. Ganapathi & D. Shanmugapriya (Eds.), *Handbook of Research on Machine and Deep Learning Applications for Cyber Security* (ss. 23-41). IGI Global. <https://doi.org/10.4018/978-1-5225-9611-0.ch002>
- Trahair, D. (2009). *Enough bull : how to retire well without the stock market, mutual funds, or even an investment advisor*. John Wiley & Sons Canada.



- Trenn, S. (2008). Multilayer perceptrons: Approximation order and necessary number of hidden units. *IEEE Transactions on Neural Networks*, 19(5), 836-844. <https://doi.org/10.1109/TNN.2007.912306>
- Umar, S., Vafaei, M., & C. Alih, S. (2021). Sensor clustering-based approach for structural damage identification under ambient vibration. *Automation in Construction*, 121, 103433. <https://doi.org/https://doi.org/10.1016/j.autcon.2020.103433>
- Usul, H., & Kocabıyık, T. (2010). Kurumsal Yatırımcıların Hisse Senedi Seçiminde Gözönünde Bulundurduğu Etmenlerin Faktör Analiziyle İncelenmesi: Türkiye Örneği. *Süleyman Demirel Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 15(3), 63-78.
- Virmani, C., Choudhary, T., Pillai, A., & Rani, M. (2020). Applications of machine learning in cyber security. P. Ganapathi & D. Shanmugapriya (Eds.), *Handbook of Research on Machine and Deep Learning Applications for Cyber Security* (ss. 83-103). IGI Global. <https://doi.org/10.4018/978-1-5225-9611-0.ch005>
- Wang, K., Huang, S., & Chen, Y. (2008, 18-20 Oct. 2008). Mutual Fund Performance Evaluation System Using Fast Adaptive Neural Network Classifier. 2008 Fourth International Conference on Natural Computation,
- Wang, P., Fan, E., & Wang, P. (2020). Comparative Analysis of Image Classification Algorithms Based on Traditional Machine Learning and Deep Learning. *Pattern Recognition Letters*. <https://doi.org/10.1016/j.patrec.2020.07.042>
- Wankhade, C. (2016). *Mutual Funds For All*. Chanchal Wankhade.
- White, T. (2020). *Summary prospectus*.
- Wu, W., Chen, J., Yang, Z., & Tindall, M. L. (2021). A Cross-Sectional Machine Learning Approach for Hedge Fund Return Prediction and Selection. *Management Science*, 67(7), 4577-4601. <https://doi.org/10.1287/mnsc.2020.3696>
- Xidonas, P., Mavrotas, G., Krintas, T., Psarras, J., & Zopounidis, C. (2012). *Multicriteria portfolio management* (Vol. 69). Springer. <https://doi.org/10.1007/978-1-4614-3670-6>
- Yalaman, A. (2019). Yatırım fonu katılma belgesi yatırımları. F. Temizel (Ed.), *Menkul kıymet yatırımları* (ss. 140-167). Anadolu Üniversitesi.
- Yu, O. S. (2007). *Technology portfolio planning and management: Practical concepts and tools*. Springer Science + Business Media.
- Yücel, E. (2018). *Türev Finansal Araçlar ve Muhasebe İşlemleri*. Dora Basım-Yayın Dağıtım.
- Yücel, Ö. (2016). BİST Endekslerinin Risk Temelli Performans Karşılaştırması. *İşletme ve İktisat Çalışmaları Dergisi*, 4(4), 151-164.
- Zhang, J., Yuan, H., & Dong, H. (2020). Introduction to Deep Learning. H. Dong, Z. Ding, & S. Zhang (Eds.), *Deep Reinforcement Learning: Fundamentals, Research and Applications* (ss. 3-46). Springer Singapore. [https://doi.org/10.1007/978-981-15-4095-0\\_1](https://doi.org/10.1007/978-981-15-4095-0_1)
- Ziraatportföy. (2021). *Yatırım fonları*. 25.09.2021 tarihinde <https://www.ziraatportfoy.com.tr/tr/yatirim-fonlari> adresinden erişildi.
- Zitar, R. A., & Hussain, H. (2019). A mirroring neural network approach for encryption/decryption of data *ICIC Express Letters*, 13(11), 1057-1064. <https://doi.org/10.24507/icicel.13.11.1057>
- Zounemat-Kermani, M., Stephan, D., & Hinkelmann, R. (2019). Multivariate NARX neural network in prediction gaseous emissions within the influent chamber of

wastewater treatment plants. *Atmospheric Pollution Research*, 10(6), 1812-1822.  
<https://doi.org/10.1016/j.apr.2019.07.013>

## **EKLER**

- EK 1** Yatırım fonu kapanış fiyatının tahminine ilişkin önceki arařtırmalarda elde edilen performans ölçüt deęerleri ile tez çalışmasında elde edilen performans ölçüt deęerlerinin karşılaştırılması

## EK 1

**Ek Çizelge 1.** Yatırım fonu kapanış fiyatının tahminine ilişkin önceki araştırmalarda elde edilen performans ölçüt değerleri ile tez çalışmasında elde edilen performans ölçüt değerlerinin karşılaştırılması

Çalışma	Yöntem	İncelenen Fon	Performans Ölçütleri						
			SSE	MSE	RMSE	MAE	MAPE	R	R <sup>2</sup>
Chiang vd. (1996)	YSA-1	101 Amerikan Fonunun Ortalaması	-	-	-	-	8,76	-	0,90-0,99
Akel ve Karacameydan (2012)	YSA-1	19 tane A tipi fondan en iyi sonucu veren fon (A1)	0,010831	0,000387	0,019667	-	-	-	0,7589
	YSA-1	19 tane B tipi fondan en iyi sonucu veren fon (B12)	0,004047	0,000145	0,012022	-	-	-	0,77315
Priyadarshini ve Babu (2012)	YSA-1	Sahara	-	4,4486	2,101	1,432708	4,1	-	-
	Çoklu Regresyon	Sahara	-	7,9384	2,8175	2,101	5,25	-	-
Anish ve Majhi (2015a)	RBF	Birla Sunlife	-	-	0,3126	-	0,9349	-	-
		Franklin India Bluechip	-	-	0,3421	-	1,3133	-	-
		HDFC	-	-	0,2056	-	1,0938	-	-
		ICICI	-	-	0,2417	-	0,9574	-	-
		UTI	-	-	0,145	-	1,1339	-	-
	FLANN	Birla Sunlife	-	-	0,3123	-	0,9352	-	-
		Franklin India Bluechip	-	-	0,3434	-	1,2042	-	-
		HDFC	-	-	0,2111	-	1,1141	-	-
		ICICI	-	-	0,2453	-	0,9927	-	-
		UTI	-	-	0,1285	-	0,9538	-	-
	RBF+FLANN	Birla Sunlife	-	-	0,3026	-	0,9072	-	-
		Franklin India Bluechip	-	-	0,3406	-	1,1911	-	-
		HDFC	-	-	0,2081	-	0,9848	-	-
		ICICI	-	-	0,3115	-	0,9372	-	-
		UTI	-	-	0,1543	-	0,9342	-	-
Anish ve Majhi (2015b)	MLP	Birla Sunlife	-	-	0,065	-	2,442	-	-
		Franklin India Bluechip	-	-	0,032	-	3,852	-	-
		HDFC	-	-	0,082	-	4,851	-	-
		ICICI	-	-	0,038	-	2,544	-	-
		UTI	-	-	0,034	-	2,896	-	-
	FLANN	Birla Sunlife	-	-	0,3123	-	0,9352	-	-
		Franklin India Bluechip	-	-	0,3434	-	1,2042	-	-
		HDFC	-	-	0,2111	-	1,1141	-	-
		ICICI	-	-	0,2453	-	0,9927	-	-
		UTI	-	-	0,1285	-	0,9538	-	-

**Ek Çizelge 1.** Yatırım fonu kapanış fiyatının tahminine ilişkin önceki araştırmalarda elde edilen performans ölçüt değerleri ile tez çalışmasında elde edilen performans ölçüt değerlerinin karşılaştırılması (devam)

Narula vd. (2015)	FLANN	HDFC (7 gün)	-	-	-	0,831	-	-	-
		HDFC (15 gün)	-	-	-	1,0132	-	-	-
	MLP	HDFC (7 gün)	-	-	-	5,444	-	-	-
		HDFC (15 gün)	-	-	-	5,962	-	-	-
	RBF	HDFC (7 gün)	-	-	-	0,668	-	-	-
		HDFC (15 gün)	-	-	-	1,549	-	-	-
Priyadarshini (2015)	YSA-1	Sahara	-	6,115	2,473	1,9808	3,68	-	-
	ARIMA	Sahara	-	13,5634	3,6829	2,974	5,527	-	-
Anish ve Majhi (2016)	MLANN	Birla Sunlife	-	-	0,075	-	2,673	-	-
		ICICI	-	-	0,039	-	3,927	-	-
		SBI BlueChip	-	-	0,053	-	4,722	-	-
		UTI	-	-	0,036	-	3,172	-	-
	FLANN	Birla Sunlife	-	-	0,3373	-	1,5458	-	-
		ICICI	-	-	0,3391	-	1,5858	-	-
		SBI BlueChip	-	-	0,3356	-	1,5673	-	-
		UTI	-	-	0,2187	-	1,691	-	-
	FFLANN	Birla Sunlife	-	-	0,4500	-	1,5083	-	-
		ICICI	-	-	0,3629	-	1,5653	-	-
		SBI BlueChip	-	-	0,2026	-	1,1877	-	-
		UTI	-	-	0,2058	-	1,5413	-	-
Hota vd. (2018)	ELM	SBI Magnum (1 gün)	-	-	0,00061	-	0,005196	-	-
		SBI Magnum (3 gün)	-	-	0,00284	-	0,009241	-	-
		SBI Magnum (5 gün)	-	-	0,00298	-	0,009591	-	-
		SBI Magnum (7 gün)	-	-	0,00315	-	0,009846	-	-
		UTI (1 gün)	-	-	0,001921	-	0,009125	-	-
		UTI (3 gün)	-	-	0,002015	-	0,009456	-	-
		UTI (5 gün)	-	-	0,002419	-	0,009811	-	-
		UTI (7 gün)	-	-	0,002973	-	0,010254	-	-
	ELM+DSA	SBI Magnum (1 gün)	-	-	0,00026	-	<b>0,00190</b>	-	-
		SBI Magnum (3 gün)	-	-	0,00091	-	0,006312	-	-
		SBI Magnum (5 gün)	-	-	0,00098	-	0,006728	-	-
		SBI Magnum (7 gün)	-	-	0,00099	-	0,006824	-	-
		UTI (1 gün)	-	-	0,001046	-	0,007625	-	-
		UTI (3 gün)	-	-	0,001231	-	0,007854	-	-
UTI (5 gün)		-	-	0,001232	-	0,008016	-	-	
UTI (7 gün)		-	-	0,005129	-	0,008729	-	-	
Rani ve Chandar (2018)	YSA-1	HDFC	-	357,7531	-	-	-	0,9801	-

**Ek Çizelge 1.** Yatırım fonu kapanış fiyatının tahminine ilişkin önceki araştırmalarda elde edilen performans ölçüt değerleri ile tez çalışmasında elde edilen performans ölçüt değerlerinin karşılaştırılması (devam)

Hota vd. (2020)	YSA	SBI magnum (1 gün)	-	-	0,4999	-	2,6005	-	-
		SBI magnum (3 gün)	-	-	0,4998	-	2,6107	-	-
		SBI magnum (5 gün)	-	-	0,4998	-	2,6775	-	-
		SBI magnum (7 gün)	-	-	0,4999	-	2,6962	-	-
		SBI magnum (15 gün)	-	-	0,5312	-	2,9012	-	-
		SBI magnum (30 gün)	-	-	0,5426	-	2,9398	-	-
		SBI magnum (1 gün)	-	-	0,4999	-	2,6005	-	-
		UTI (1 gün)	-	-	0,5	-	2,6351	-	-
		UTI (3 gün)	-	-	0,5001	-	2,6513	-	-
		UTI (5 gün)	-	-	0,5001	-	2,6622	-	-
		UTI (7 gün)	-	-	0,5055	-	2,6853	-	-
		UTI (15 gün)	-	-	0,55	-	2,9099	-	-
	YSA+GA	SBI magnum (1 gün)	-	-	0,4998	-	2,4169	-	-
		SBI magnum (3 gün)	-	-	0,4996	-	2,4800	-	-
		SBI magnum (5 gün)	-	-	0,4996	-	2,5635	-	-
		SBI magnum (7 gün)	-	-	0,4998	-	2,5737	-	-
		SBI magnum (15 gün)	-	-	0,5166	-	2,7642	-	-
		SBI magnum (30 gün)	-	-	0,5091	-	2,8673	-	-
		UTI (1 gün)	-	-	0,4998	-	2,4152	-	-
		UTI (3 gün)	-	-	0,4999	-	2,4247	-	-
		UTI (5 gün)	-	-	0,4999	-	2,4480	-	-
		UTI (7 gün)	-	-	0,5	-	2,4804	-	-
		UTI (15 gün)	-	-	0,4998	-	2,8261	-	-
		UTI (30 gün)	-	-	0,5011	-	2,8272	-	-
	YSA+PSO	SBI magnum (1 gün)	-	-	0,4998	-	1,6680	-	-
		SBI magnum (3 gün)	-	-	0,4994	-	1,6728	-	-
		SBI magnum (5 gün)	-	-	0,4998	-	1,6909	-	-
		SBI magnum (7 gün)	-	-	0,4998	-	1,7319	-	-
		SBI magnum (15 gün)	-	-	0,4993	-	1,8700	-	-
		SBI magnum (30 gün)	-	-	0,4999	-	1,9629	-	-
		UTI (1 gün)	-	-	0,4995	-	1,8957	-	-
		UTI (3 gün)	-	-	0,4995	-	1,8963	-	-
		UTI (5 gün)	-	-	0,4997	-	2,0611	-	-

**Ek Çizelge 1.** Yatırım fonu kapanış fiyatının tahminine ilişkin önceki araştırmalarda elde edilen performans ölçüt değerleri ile tez çalışmasında elde edilen performans ölçüt değerlerinin karşılaştırılması (devam)

Hota vd. (2020)	YSA+PSO	UTI (7 gün)	-	-	0,4998	-	2,0779	-	-
		UTI (15 gün)	-	-	0,4992	-	1,9062	-	-
		UTI (30 gün)	-	-	0,4995	-	1,9558	-	-
	YSA+DE	SBI magnum (1 gün)	-	-	0,4998	-	2,1780	-	-
		SBI magnum (3 gün)	-	-	0,4996	-	2,2294	-	-
		SBI magnum (5 gün)	-	-	0,4997	-	2,3400	-	-
		SBI magnum (7 gün)	-	-	0,4998	-	2,3732	-	-
		SBI magnum (15 gün)	-	-	0,4998	-	2,1017	-	-
		SBI magnum (30 gün)	-	-	0,501	-	2,1030	-	-
		UTI (1 gün)	-	-	0,4998	-	2,3050	-	-
		UTI (3 gün)	-	-	0,4999	-	2,3184	-	-
		UTI (5 gün)	-	-	0,4999	-	2,3240	-	-
		UTI (7 gün)	-	-	0,4999	-	2,3417	-	-
		UTI (15 gün)	-	-	0,4999	-	2,0303	-	-
		UTI (30 gün)	-	-	0,501	-	2,1522	-	-
		YSA+EHO	SBI magnum (1 gün)	-	-	0,4985	-	1,2290	-
	SBI magnum (3 gün)		-	-	0,4984	-	1,3100	-	-
	SBI magnum (5 gün)		-	-	0,4997	-	1,3159	-	-
	SBI magnum (7 gün)		-	-	0,4989	-	1,3739	-	-
	SBI magnum (15 gün)		-	-	0,4983	-	1,4502	-	-
	SBI magnum (30 gün)		-	-	0,4989	-	1,4947	-	-
UTI (1 gün)	-		-	0,4978	-	1,3111	-	-	
UTI (3 gün)	-		-	0,4983	-	1,3338	-	-	
UTI (5 gün)	-		-	0,4986	-	1,3369	-	-	
UTI (7 gün)	-		-	0,4988	-	1,3900	-	-	
UTI (15 gün)	-		-	0,4981	-	1,4674	-	-	
UTI (30 gün)	-		-	0,4995	-	1,4939	-	-	
Koudjonou ve Rout (2020)	GRU+MTSF	Birla Sunlife (1 gün)	-	-	0,3356	-	1,0154	-	-
		Birla Sunlife (3 gün)	-	-	0,5339	-	1,6721	-	-
		Birla Sunlife (7 gün)	-	-	0,8759	-	2,7794	-	-
		Franklin Bluechip (1 gün)	-	-	0,3711	-	1,3884	-	-
		Franklin Bluechip (3 gün)	-	-	0,6897	-	2,632	-	-

**Ek Çizelge 1.** Yatırım fonu kapanış fiyatının tahminine ilişkin önceki araştırmalarda elde edilen performans ölçüt değerleri ile tez çalışmasında elde edilen performans ölçüt değerlerinin karşılaştırılması (devam)

Koudjonou ve Rout (2020)	GRU+MTSF	Franklin Bluechip (7 gün)	-	-	1,0896	-	4,4892	-	-
		HDFC (1 gün)	-	-	0,2153	-	1,1509	-	-
		HDFC (3 gün)	-	-	0,363	-	1,955	-	-
		HDFC (7 gün)	-	-	0,6006	-	3,3586	-	-
		ICICI (1 gün)	-	-	0,2399	-	0,9984	-	-
		ICICI (3 gün)	-	-	0,3979	-	1,632	-	-
		ICICI (7 gün)	-	-	0,6417	-	2,6604	-	-
		UTI (1 gün)	-	-	0,1293	-	1,0016	-	-
		UTI (3 gün)	-	-	0,1895	-	1,535	-	-
		UTI (7 gün)	-	-	0,2854	-	2,3062	-	-
	LSTM+MTSF	Birla Sunlife (1 gün)	-	-	0,3902	-	1,2397	-	-
		Birla Sunlife (3 gün)	-	-	0,5724	-	1,7892	-	-
		Birla Sunlife (7 gün)	-	-	0,9622	-	3,0913	-	-
		Franklin Bluechip (1 gün)	-	-	0,4076	-	1,5059	-	-
		Franklin Bluechip (3 gün)	-	-	0,6947	-	2,8454	-	-
		Franklin Bluechip (7 gün)	-	-	1,1704	-	4,9696	-	-
		HDFC (1 gün)	-	-	0,2508	-	1,4033	-	-
		HDFC (3 gün)	-	-	0,3699	-	1,9677	-	-
		HDFC (7 gün)	-	-	0,5831	-	3,2534	-	-
		ICICI (1 gün)	-	-	0,2407	-	1,0236	-	-
		ICICI (3 gün)	-	-	0,4242	-	1,7215	-	-
		ICICI (7 gün)	-	-	0,7001	-	2,8806	-	-
		UTI (1 gün)	-	-	0,1315	-	1,0109	-	-
		UTI (3 gün)	-	-	0,1893	-	1,562	-	-
	UTI (7 gün)	-	-	0,2817	-	2,2845	-	-	
	GRU+MTMF	Birla Sunlife (1 gün)	-	-	0,2824	-	0,8953	-	-
		Birla Sunlife (3 gün)	-	-	0,5454	-	1,7138	-	-
		Birla Sunlife (7 gün)	-	-	0,9323	-	3,8862	-	-
		Franklin Bluechip (1 gün)	-	-	0,3241	-	1,2323	-	-
		Franklin Bluechip (3 gün)	-	-	0,631	-	2,4392	-	-
		Franklin Bluechip (7 gün)	-	-	0,9335	-	3,887	-	-



**Ek Çizelge 1.** Yatırım fonu kapanış fiyatının tahminine ilişkin önceki araştırmalarda elde edilen performans ölçüt değerleri ile tez çalışmasında elde edilen performans ölçüt değerlerinin karşılaştırılması (devam)

Koudjonou ve Rout (2020)	GRU+MTMF	HDFC (1 gün)	-	-	0,1627	-	0,8952	-	-
		HDFC (3 gün)	-	-	0,379	-	2,0572	-	-
		HDFC (7 gün)	-	-	0,591	-	3,3572	-	-
		ICICI (1 gün)	-	-	0,2152	-	0,9228	-	-
		ICICI (3 gün)	-	-	0,4053	-	1,6755	-	-
		ICICI (7 gün)	-	-	0,3079	-	2,5162	-	-
		UTI (1 gün)	-	-	0,114	-	0,9104	-	-
		UTI (3 gün)	-	-	0,1863	-	1,5676	-	-
	UTI (7 gün)	-	-	0,6539	-	2,7478	-	-	
	LSTM+MTMF	Birla Sunlife (1 gün)	-	-	0,2821	-	0,9016	-	-
		Birla Sunlife (3 gün)	-	-	0,5349	-	1,6856	-	-
		Birla Sunlife (7 gün)	-	-	0,952	-	3,1332	-	-
		Franklin Bluechip (1 gün)	-	-	0,3518	-	1,2956	-	-
		Franklin Bluechip (3 gün)	-	-	0,6231	-	2,4416	-	-
		Franklin Bluechip (7 gün)	-	-	1,0739	-	4,3629	-	-
		HDFC (1 gün)	-	-	0,1651	-	0,8964	-	-
		HDFC (3 gün)	-	-	0,3883	-	2,1831	-	-
		HDFC (7 gün)	-	-	0,6014	-	3,3649	-	-
		ICICI (1 gün)	-	-	0,2062	-	0,8718	-	-
		ICICI (3 gün)	-	-	0,3946	-	1,6474	-	-
ICICI (7 gün)		-	-	0,3064	-	2,5377	-	-	
UTI (1 gün)	-	-	0,1116	-	0,8852	-	-		
UTI (3 gün)	-	-	0,1878	-	1,5723	-	-		
UTI (7 gün)	-	-	0,3473	-	2,8456	-	-		
Hota vd. (2021a)	MLP	SBI magnum (1 gün)	-	-	1,6185	-	3,7288	-	-
		SBI magnum (3 gün)	-	-	1,7654	-	4,0564	-	-
		SBI magnum (7 gün)	-	-	2,1205	-	4,8601	-	-
		SBI magnum (15 gün)	-	-	2,4217	-	5,5541	-	-
	ELM	SBI magnum (1 gün)	-	-	0,00061	-	0,005196	-	-
		SBI magnum (3 gün)	-	-	0,00284	-	0,009241	-	-
		SBI magnum (7 gün)	-	-	0,00315	-	0,009846	-	-
		SBI magnum (15 gün)	-	-	0,00685	-	0,062100	-	-

**Ek Çizelge 1.** Yatırım fonu kapanış fiyatının tahminine ilişkin önceki araştırmalarda elde edilen performans ölçüt değerleri ile tez çalışmasında elde edilen performans ölçüt değerlerinin karşılaştırılması (devam)

Hota vd. (2021a)	FLANN	SBI magnum (1 gün)	-	-	1,5663	-	3,5943	-	-
		SBI magnum (3 gün)	-	-	1,6783	-	3,8291	-	-
		SBI magnum (7 gün)	-	-	2,1318	-	4,8857	-	-
		SBI magnum (15 gün)	-	-	2,3369	-	5,3397	-	-
Hota vd. (2021b)	FLANN	UTI (1 gün)	-	-	3,4876	-	2,8429	-	-
		UTI (5 gün)	-	-	4,2280	-	3,765	-	-
		TATA (1 gün)	-	-	4,5740	-	3,125	-	-
		TATA (5 gün)	-	-	3,6628	-	2,463	-	-
	FLANN+FA	UTI (1 gün)	-	-	2,8965	-	2,0934	-	-
		UTI (5 gün)	-	-	3,7567	-	3,1256	-	-
		TATA (1 gün)	-	-	3,7734	-	2,7693	-	-
		TATA (5 gün)	-	-	3,2570	-	1,87	-	-
Majhi vd. (2021)	AARMA	Escorts Leading Sectors Fund- Growth (1 gün)	-	-	0,2679	-	0,8784	-	-
		Escorts Leading Sectors Fund- Growth (3 gün)	-	-	0,4222	-	1,3922	-	-
		Escorts Leading Sectors Fund- Growth (5 gün)	-	-	0,5362	-	1,7742	-	-
		Escorts Leading Sectors Fund- Growth (7 gün)	-	-	0,6116	-	2,0995	-	-
		Escorts Leading Sectors Fund- Growth (15 gün)	-	-	0,8217	-	2,9266	-	-
		Kotak Midcap- Growth (1 gün)	-	-	0,7609	-	1,0538	-	-
		Kotak Midcap- Growth (3 gün)	-	-	1,1570	-	1,6292	-	-
		Kotak Midcap- Growth (5 gün)	-	-	1,4475	-	2,1425	-	-
		Kotak Midcap- Growth (7 gün)	-	-	1,6513	-	2,5538	-	-
		Kotak Midcap- Growth (15 gün)	-	-	2,3416	-	3,7226	-	-
		L&T India Value fund- Growth (1 gün)	-	-	0,3954	-	1,2095	-	-

**Ek Çizelge 1.** Yatırım fonu kapanış fiyatının tahminine ilişkin önceki araştırmalarda elde edilen performans ölçüt değerleri ile tez çalışmasında elde edilen performans ölçüt değerlerinin karşılaştırılması (devam)

Majhi vd. (2021)	AARMA	L&T India Value fund- Growth (3 gün)	-	-	0,596	-	1,8653	-	-
		L&T India Value fund- Growth (5 gün)	-	-	0,7434	-	2,4483	-	-
		L&T India Value fund- Growth (7 gün)	-	-	0,8392	-	2,8927	-	-
		L&T India Value fund- Growth (15 gün)	-	-	1,1725	-	4,0375	-	-
	AMA	Escorts Leading Sectors Fund- Growth (1 gün)	-	-	0,2736	-	0,8857	-	-
		Escorts Leading Sectors Fund- Growth (3 gün)	-	-	0,4139	-	1,3920	-	-
		Escorts Leading Sectors Fund- Growth (5 gün)	-	-	0,5216	-	1,7708	-	-
		Escorts Leading Sectors Fund- Growth (7 gün)	-	-	0,5914	-	2,0650	-	-
		Escorts Leading Sectors Fund- Growth (15 gün)	-	-	0,7886	-	2,7426	-	-
		Kotak Midcap- Growth (1 gün)	-	-	1,0825	-	1,3459	-	-
		Kotak Midcap- Growth (3 gün)	-	-	1,3427	-	1,8679	-	-
		Kotak Midcap- Growth (5 gün)	-	-	1,5624	-	2,2535	-	-
		Kotak Midcap- Growth (7 gün)	-	-	1,7213	-	2,5714	-	-
		Kotak Midcap- Growth (15 gün)	-	-	2,3338	-	3,6376	-	-
		L&T India Value fund- Growth (1 gün)	-	-	0,3732	-	1,0489	-	-
		L&T India Value fund- Growth (3 gün)	-	-	0,5661	-	1,7061	-	-

**Ek Çizelge 1.** Yatırım fonu kapanış fiyatının tahminine ilişkin önceki araştırmalarda elde edilen performans ölçüt değerleri ile tez çalışmasında elde edilen performans ölçüt değerlerinin karşılaştırılması (devam)

Majhi vd. (2021)	AMA	L&T India Value fund- Growth (5 gün)	-	-	0,7084	-	2,2386	-	-
		L&T India Value fund- Growth (7 gün)	-	-	0,7919	-	2,6274	-	-
		L&T India Value fund- Growth (15 gün)	-	-	1,1099	-	3,7276	-	-
	FLANN	Escorts Leading Sectors Fund- Growth (1 gün)	-	-	0,7030	-	2,8361	-	-
		Escorts Leading Sectors Fund- Growth (3 gün)	-	-	0,7990	-	3,2074	-	-
		Escorts Leading Sectors Fund- Growth (5 gün)	-	-	0,8707	-	3,4533	-	-
		Escorts Leading Sectors Fund- Growth (7 gün)	-	-	0,9349	-	3,7020	-	-
		Escorts Leading Sectors Fund- Growth (15 gün)	-	-	1,0538	-	4,1257	-	-
		Kotak Midcap- Growth (1 gün)	-	-	2,9490	-	4,2756	-	-
		Kotak Midcap- Growth (3 gün)	-	-	2,9222	-	4,2214	-	-
		Kotak Midcap- Growth (5 gün)	-	-	2,9118	-	4,2535	-	-
		Kotak Midcap- Growth (7 gün)	-	-	2,8834	-	4,2789	-	-
		Kotak Midcap- Growth (15 gün)	-	-	3,2715	-	4,8862	-	-
		L&T India Value fund- Growth (1 gün)	-	-	0,8254	-	2,5049	-	-
		L&T India Value fund- Growth (3 gün)	-	-	0,5958	-	1,805	-	-
		L&T India Value fund- Growth (5 gün)	-	-	0,7408	-	2,3811	-	-

**Ek Çizelge 1.** Yatırım fonu kapanış fiyatının tahminine ilişkin önceki araştırmalarda elde edilen performans ölçüt değerleri ile tez çalışmasında elde edilen performans ölçüt değerlerinin karşılaştırılması (devam)

Majhi vd. (2021)	FLANN	L&T India Value fund- Growth (7 gün)	-	-	0,8327	-	2,8573	-	-
		L&T India Value fund- Growth (15 gün)	-	-	1,1943	-	4,1625	-	-
	BPNN Hibrit Model	Escorts Leading Sectors Fund- Growth (1 gün)	-	-	0,2432	-	0,6188	-	-
		Escorts Leading Sectors Fund- Growth (3 gün)	-	-	0,3812	-	1,2193	-	-
		Escorts Leading Sectors Fund- Growth (5 gün)	-	-	0,4465	-	1,4188	-	-
		Escorts Leading Sectors Fund- Growth (7 gün)	-	-	0,5342	-	1,7760	-	-
		Escorts Leading Sectors Fund- Growth (15 gün)	-	-	0,7455	-	2,0966	-	-
		Kotak Midcap- Growth (1 gün)	-	-	0,7279	-	0,9491	-	-
		Kotak Midcap- Growth (3 gün)	-	-	1,0715	-	1,4354	-	-
		Kotak Midcap- Growth (5 gün)	-	-	1,2484	-	1,8539	-	-
		Kotak Midcap- Growth (7 gün)	-	-	1,4215	-	2,2128	-	-
		Kotak Midcap- Growth (15 gün)	-	-	2,0669	-	3,4765	-	-
		L&T India Value fund- Growth (1 gün)	-	-	0,3559	-	0,9744	-	-
		L&T India Value fund- Growth (3 gün)	-	-	0,5615	-	1,689	-	-
		L&T India Value fund- Growth (5 gün)	-	-	0,6165	-	1,8702	-	-
		L&T India Value fund- Growth (7 gün)	-	-	0,7655	-	2,3697	-	-

**Ek Çizelge 1.** Yatırım fonu kapanış fiyatının tahminine ilişkin önceki araştırmalarda elde edilen performans ölçüt değerleri ile tez çalışmasında elde edilen performans ölçüt değerlerinin karşılaştırılması (devam)

Majhi vd. (2021)	BPNN Hibrit Model	L&T India Value fund- Growth (15 gün)	-	-	1.0347	-	3.7376	-	-
Birinci Amaç	YSA-1	DBP	6,41E-06	3,79E-08	0,000195	0,000141	0,407553	0,999578	0,999156
		IST	7,34E-05	4,34E-07	0,000659	0,000481	2,155167	0,991368	0,982811
	YSA-2	DBP	3,02E-06	1,79E-08	0,000134	0,0000969	0,280547	0,999787	0,999573
		IST	0,000058	3,43E-07	0,000586	0,000412	1,848753	0,994256	0,988545
	NARX	DBP	3,11E-07	1,84E-09	4,29E-05	2,99E-05	0,082591	0,999981	0,999961
		IST	1,49E-08	8,83E-11	9,4E-06	7,25E-06	0,029575	0,999998	0,999997
İkinci Amaç	YSA-1	DBP	1,04E-06	6,18E-09	7,86E-05	5,66E-05	0,168420	0,999934	0,999868
		IST	1,65E-06	9,74E-09	9,87E-05	7,66E-05	0,314404	0,999823	0,999646
	YSA-2	DBP	4,70E-07	2,78E-09	5,27E-05	3,69E-05	0,108825	0,999970	0,999940
		IST	3,91E-07	2,32E-09	4,81E-05	3,52E-05	0,141640	0,999962	0,999924
	NARX	DBP	2,89E-07	1,71E-09	4,13E-05	2,96E-05	0,083210	0,999980	0,999961
		IST	<b>5,76E-09</b>	<b>3,41E-11</b>	<b>5,84E-06</b>	<b>4,64E-06</b>	0,018583	<b>1,000000</b>	<b>0,999999</b>
Optimal Performans Ölçüt Değerleri			5,76E-09	3,41E-11	5,84E-06	4,64E-06	0,00190	1,000000	0,999999

## ÖZGEÇMİŞ

Adı Soyadı : Ümit YILMAZ  
Doğum Yeri ve Tarihi : Bursa 27/06/1983  
Yabancı Dil : İngilizce

Eğitim Durumu  
Lise : Bursa Çınar Lisesi  
Lisans : Dumlupınar Üniversitesi Endüstri Mühendisliği  
Yüksek Lisans : Uludağ Üniversitesi Endüstri Mühendisliği

Çalıştığı Kurum/Kurumlar : Balıkesir Üniversitesi Bigadiç Meslek Yüksekokulu

İletişim (e-posta) : umityilmaz@balikesir.edu.tr

Yayınları :

Yazılan ulusal/uluslararası kitaplar veya kitaplardaki bölümler:

Erdoğan, M. O., Yılmaz, Ü., Özçekiç, Ü. & Şaykol, E. (2019). Yapay Sinir Ağları ile Melanom Cilt Kanserinin Tespiti. Geleceğin Dünyasında Bilimsel ve Mesleki Çalışmalar 2019: Bilgisayar Mühendisliği (ss. 104-114). Bursa: Ekin Basım Yayın Dağıtım.

Duman, T., Yılmaz, Ü., Özçekiç E. & Yılmaz, A. (2019). Bulanık Mantık Temelli Bireysel Kredi Başvurusu Değerlendirme Sistemi Tasarımı. Geleceğin Dünyasında Bilimsel ve Mesleki Çalışmalar 2019: Bilgisayar Mühendisliği (ss. 115-123). Bursa: Ekin Basım Yayın Dağıtım.

Sakarya, Ş., Yılmaz, Ü. & Ögütçen, İ. (2019). Üniversitede Öğrenim Gören Kız Öğrencilerin Girişimcilik Niyetlerinin Belirlenmesi: Bigadiç Meslek Yüksekokulu Örneği. Strateji Odaklı Akademik Değerlendirmeler (ss. 137 -158). Klaipeda: Strategic Researches Academy.

Yılmaz, Ü. (2017). Ticari Matematik. Bursa: Ekin Basım Yayın Dağıtım.

Uluslararası hakemli dergilerde yayımlanan makaleler:

Yılmaz, A., Orbak, A. Y., Yılmaz, Ü. & Özçekiç, E. (2021). COVID-19 Süresince İnsanların Sosyal Ağlar Üzerinde Dışa Vurdukları Duygusal Tepkilerin Doğal Dil İşleme Yöntemleriyle Tespit Edilmesi: Ekşi Sözlük Örneği. Acta Infologica, 5 (2), 319-331.

Yılmaz, Ü. & Kuvat, Ö. (2021). Nesnelerin İnterneti Teknolojisinin Lojistik Faaliyetlerindeki Uygulama Alanları ve Verimliliğe Etkileri. Avrupa Bilim ve Teknoloji Dergisi, Ejosat 2021 Supplement 1, 746-754. DOI: 10.31590/ejosat.1004953

Sakarya, Ş., Yılmaz, Ü. (2019). Derin Öğrenme Mimarisi Kullanarak BİST30 İndeksinin Tahmini. European Journal of Educational and Social Sciences , 4 (2) , 106-121.

Yılmaz, Ü. & Duman, B. (2019). Lojistik 4.0 Kavramına Genel Bir Bakış: Geçmişten Bugüne Gelişim ve Değişimi. Bilecik Şeyh Edebali Üniversitesi Sosyal Bilimler Dergisi, 4 (1), 186-200. DOI: 10.33905/bseusbed.465962

Yılmaz, Ü. (2019). İnsani Yardım Lojistiği Faaliyetlerinde İnsansız Hava Araçlarının Kullanım Alanları. Türkiye Mesleki ve Sosyal Bilimler Dergisi, (2), 43-54. DOI: 10.46236/jvosst.623075

Yılmaz, Ü. & Duman, B. (2019). Artırılmış Gerçeklik Teknolojisinin Lojistik Faaliyetleri Üzerine Olan Etkilerinin İncelenmesi. Uluslararası İnsan Çalışmaları Dergisi, 2 (3), 1-7. DOI: 10.35235/uicd.464839

Özçekiç, E. & Yılmaz, Ü. (2018). A Fuzzy Logic Model Purposing Evaluation of Transportation Management. Uluslararası Afro-Avrasya Araştırmaları Dergisi, 3 (6), 192-200.

Uluslararası hakemli dergilerde yayımlanmak üzere gönderilen makaleler:

Yılmaz, Ü. & Orbak, A. Y. (2022). Prediction Of Turkish Mutual Fund's Net Asset Value Using The Fund Portfolio Distribution. Neural Computing and Applications.