



**T.C.
ERCIYES ÜNİVERSİTESİ
SOSYAL BİLİMLER ENSTİTÜSÜ
İŞLETME ANABİLİM DALI**

**YAPAY SİNİR AĞLARI İLE HİSSE SENETLERİNİN FİYAT TAHMİNİ:
BİST ELEKTRİK ENDEKSİ ÖRNEĞİ**

**Hazırlayan
Didar GÜÇLÜ**

**Danışman
Prof. Dr. Veli AKEL**

Yüksek Lisans Tezi

Eylül 2024, KAYSERİ

Didar GÜÇLÜ

İŞLETME ANABİLİM DALI

Yüksek Lisans Tezi

2024

T.C.
ERCIYES ÜNİVERSİTESİ
SOSYAL BİLİMLER ENSTİTÜSÜ
İŞLETME ANABİLİM DALI

**YAPAY SİNİR AĞLARI İLE HİSSE SENETLERİNİN FİYAT
TAHMİNİ: BİST ELEKTRİK ENDEKSİ ÖRNEĞİ**

Hazırlayan
Didar GÜÇLÜ

Danışman
Prof. Dr. Veli AKEL

Eylül 2024, KAYSERİ

BİLİMSEL ETİĞE UYGUNLUK

Bu çalışmadaki tüm bilgilerin, akademik ve etik kurallara uygun bir şekilde elde edildiğini beyan ederim. Aynı zamanda bu kural ve davranışların gerektirdiği gibi, bu çalışmanın özünde olmayan tüm materyal ve sonuçları tam olarak aktardığımı ve referans gösterdiğimi belirtirim.

Didar GÜÇLÜ



T.C.

ERCIYES ÜNİVERSİTESİ

Sosyal Bilimler Enstitüsü Müdürlüğü

Öğrenci No : 4030530152
Anabilim Dalı : İşletme
Tez Başlığı : Yapay Sinir Ağları ile Hisse Senetlerinin Fiyat Tahmini: Bist Elektrik Endeksi Örneği

Yukarıda bilgileri verilen tez çalışmasının a) Giriş, b) Ana bölümler ve c) Sonuç kısımlarından oluşan (Kapak, Önsöz, Özet, İçindekiler ve Kaynakça hariç) toplam 95 sayfalık kısmına ilişkin 04/09/2024 tarihinde **Turnitin** intihal programından aşağıda belirtilen filtreleme uygulanarak alınmış olan özgünlük raporuna göre tezin benzerlik oranı: **13**'dir.

Filtrelemeye **alıntılar dahil** edilmiştir. Filtrelemede **yedi (7) kelimeden daha az** örtüşme içeren metin kısımları hariç tutulmuştur.

Erciyes Üniversitesi Sosyal Bilimler Enstitüsü Tez İntihal Raporu Uygulama Esaslarını inceledim ve bu uygulama esaslarında belirtilen azami benzerlik oranlarına göre tez çalışmasının herhangi bir intihal içermediğini, aksinin tespit edilmesi durumunda doğabilecek her türlü hukuki sorumluluğu kabul ettiğimi ve yukarıda vermiş olduğum bilgilerin doğru olduğunu beyan ederim.

Gereğini bilgilerinize arz ederim. 04.09.2024

Danışman: Prof. Dr. Veli AKEL

Öğrenci: Didar GÜÇLÜ

KILAVUZA UYGUNLUK

“Yapay Sinir Ağları İle Hisse Senetlerinin Fiyat Tahmini: Bist Elektrik Endeksi Örneği” başlıklı Yüksek Lisans Tezi, Erciyes Üniversitesi Lisansüstü Tez Yazım Kılavuzuna uygun olarak hazırlanmıştır.

Hazırlayan

Didar GÜÇLÜ

Danışman

Prof. Dr. Veli AKEL

İşletme ABD Başkanı

Prof. Dr. Ayşe CİNGÖZ



KABUL VE ONAY TUTANAĞI

Prof. Dr. Veli AKEL danışmanlığında **Didar GÜÇLÜ** tarafından hazırlanan “**Yapay Sinir Ağları İle Hisse Senetlerinin Fiyat Tahmini: Bist Elektrik Endeksi Örneği**” adlı bu çalışma jürimiz tarafından Erciyes Üniversitesi Sosyal Bilimler Enstitüsü **İşletme** Anabilim Dalı’nda **Yüksek Lisans** tezi olarak kabul edilmiştir.

20/08/2024

JÜRİ:

Danışman : **Prof. Dr. Veli AKEL**

Üye : **Prof. Dr. Levent ÇITAK**

Üye : **Doç. Dr. Sümeyra GAZEL**

ONAY:

Bu tezin kabulü Enstitü Yönetim Kurulu'nun /.... /..... tarih ve sayılı kararı ile onaylanmıştır.

..... /..... /

Prof. Dr. Atabey KILIÇ

Enstitü Müdürü

ÖNSÖZ

Başta bu çalışmanın tamamlanmasında emeğini esirgemedi samimi ve güler yüzüyle yardımcı olan, bilgi ve tecrübeleriyle rehberlik eden değerli danışman hocam Prof. Dr. Veli AKEL olmak üzere, tez savunmasında görüş ve önerileri ile çalışmama katkı sağlayan Prof. Dr. Levent ÇITAK hocama ve Doç. Dr. Sümeyra GAZEL hocama teşekkürlerimi sunarım. Ayrıca kıymetli vaktini ayırıp Yapay Sinir Ağlarıyla ilgili bilgileriyle destek olan Prof. Dr. Mehmet Emin YÜKSEL hocama ve eğitimleri için tüm bölüm hocalarıma, Arş. Gör. Dr. Selma ERDOĞAN GÜLİRMAK hocama teşekkür ederim. Tez konusu belirleme aşamasında bilgisiyle yol gösteren, Covid 19 nedeniyle vefat eden merhum hocam Dr. Öğr. Üyesi Talip TORUN'u rahmet ve hürmetle anıyorum.

Hayatım boyunca her zaman yanımda olan, desteklerini hiçbir zaman esirgemeyen, beni yetiştiren canım anneme ve babama, sevgili ağabeyime sonsuz teşekkürlerimi sunarım.

Didar GÜÇLÜ, Kayseri, 2024

YAPAY SINIR AĞLARI İLE HİSSE SENETLERİNİN FİYAT TAHMİNİ: BİST ELEKTRİK ENDEKSİ ÖRNEĞİ

Didar GÜÇLÜ

Erciyes Üniversitesi, Sosyal Bilimler Enstitüsü

Yüksek Lisans Tezi, Eylül 2024

Danışman: Prof. Dr. Veli AKEL

ÖZET

Firmalar ve bireylerin yatırım yaptıkları finansal araçlardan biri olan hisse senetlerinin fiyat tahmininin yapılabilmesi yatırımcının kazanç veya kayıp ile karşılaşabileceğini önceden öngörebilmesi yönünden önemli bir avantajdır. Buna göre o hisse senedine yatırım yapıp yapmamayı tercih edebilirler. Bu amaçla bu çalışmada Yapay Sinir Ağları Yöntemiyle BİST Elektrik Endeksi ve bu endekste yer alan dört hisse senedinin fiyat öngörüsü çeşitli modellerle yapılmıştır. Oluşturulan modellerde Euro, Dolar, Gram Altın, Brent Petrol, Tüketici Fiyat Endeksi (TÜFE) ve BİST100 değerleri bağımsız değişken, BİST Elektrik Endeksi ve AKENR, AKSUE, AYEN, ZOREN hisse senetleri her bir Yapay Sinir Ağı modeli için ayrı ayrı bağımlı değişkenler olarak belirlenmiştir. Ocak 2004- Mart 2024 dönemlerini kapsayan veriler MATLAB programı yardımıyla analiz edilmiş ve gerçek fiyat ile beklenen fiyat arasındaki fark, Ortalama Kare Hata (MSE) ölçütü ile incelenmiştir. Regresyon analizi sayesinde gerçek fiyat ile ulaşılan fiyatın ilişkisini gösteren R değerleri hesaplanmıştır. Analizde normalizasyonu yapılmış verilerin diğerlerine göre daha iyi sonuçlar elde ettiği görülmüştür. Normalizasyonu yapılmış veriler ile yapılan analizde %90 eğitim %10 test oranı belirlenerek yapılan analizler daha başarılı olmuştur. Eğitim fonksiyonları içinde ise Bayesian Regularization eğitim fonksiyonu daha iyi sonuçlara ulaşmıştır. Sonuç olarak Yapay Sinir Ağları Yönteminin BİST Elektrik Endeksi ve hesaplanan diğer hisse senetlerinin fiyat tahmininde başarılı olduğu görülmektedir.

Anahtar Kelimeler: Hisse Senedi Getirileri, Fiyat Tahmini, Yapay Sinir Ağları Analizi, BİST Elektrik Endeksi

FORECASTING OF STOCK PRICE WITH ARTIFICIAL NEURAL NETWORKS: BIST ELECTRICITY INDEX EXAMPLE

Didar GÜÇLÜ

Erciyes University, Graduate School of Social Sciences

Master Thesis, September 2024

Supervisor: Prof. Dr. Veli AKEL

ABSTRACT

The prediction of the price of stocks, which is one of the financial instruments that firms and individuals invest in, is an important advantage in terms of predicting in advance whether the investor will face gains or losses. Accordingly, they can choose whether or not to invest in that stock. For this purpose, in this thesis, Artificial Neural Networks are used to predict the prices of BIST Electricity Index and four stocks in this index with various models. In the models created, Euro, Dollar, Gram Gold, Brent Oil, Consumer Price Index (CPI) and BIST100 values were determined as independent variables and BIST Electricity Index and AKENR, AKSUE, AYEN, ZOREN stocks were determined as dependent variables separately for each Artificial Neural Network model. The data covering the period between January 2004 and March 2024 were analyzed with the help of MATLAB program and the difference between the actual price and the expected price was examined with the Mean Squared Error (MSE) measure. Through regression analysis, R values showing the relationship between the actual price and the achieved price were calculated. In the analysis, it was seen that normalized data obtained better results than raw data. In the analysis made with normalized data, made by determining 90% training and 10% test ratio was more successful. Among the training functions, Bayesian Regularization training function achieved better results. As a result, it is seen that the Artificial Neural Network Method is successful in price prediction of BIST Electricity Index and other stocks calculated.

Keywords: Stock Returns, Price Predictions, Artificial Neural Network Analysis, BIST Electricity Index

İÇİNDEKİLER

YAPAY SİNİR AĞLARI İLE HİSSE SENETLERİNİN FİYAT TAHMİNİ: BİST ELEKTRİK ENDEKSİ ÖRNEĞİ

BİLİMSEL ETİĞE UYGUNLUK	i
TEZ ÖZGÜNLÜK SAYFASI	ii
KILAVUZA UYGUNLUK	iii
KABUL VE ONAY TUTANAĞI.....	iv
ÖNSÖZ.....	v
ÖZET.....	vi
ABSTRACT	vii
İÇİNDEKİLER.....	viii
SİMGELER VE KISALTMALAR LİSTESİ.....	xii
TABLolar LİSTESİ.....	xiii
ŞEKİLLER LİSTESİ.....	xv
GİRİŞ.....	1

BİRİNCİ BÖLÜM

YATIRIM KAVRAMI VE RİSK KARŞISINDA YATIRIMCILARIN TÜRLERİ

1.1.Yatırım Kavramı.....	3
1.2.Toplam Riskin Kaynakları.....	4
1.2.1.SistematiK Risk	8
1.2.1.1.Satın Alma Gücü (Enflasyon) Riski.....	9
1.2.1.2.Faiz Oranı Riski	10
1.2.1.3.Piyasa (Pazar) Riski	11
1.2.1.4.Döviz Kuru Riski	12
1.2.1.5.Politik Risk.....	12

1.2.2.Sistematik Olmayan Risk.....	13
1.2.2.1.Finansal Risk	13
1.2.2.2.Yönetim Riski	14
1.2.2.3.İş ve Endüstri Riski	15
1.3.Kayıtsızlık (Farksızlık) Eğrileri.....	15
1.3.1.Fayda Fonksiyonu ve Risk Karşısında Yatırımcı Tutumları	17
1.3.2.Yatırımcı Türleri	18
1.3.2.1.Risk Seven Yatırımcı	18
1.3.2.2.Riske Kayıtsız Yatırımcı	19
1.3.2.3.Riskten Kaçan Yatırımcı	20
1.4. Beklenen Getiri ve Risk Hesabı.....	21
1.4.1. Olasılık Dağılımı ile Beklenen Getiri ve Risk Hesaplaması.....	22
1.4.2. Tarihsel Veriler Yardımı ile Beklenen Getiri ve Risk Hesaplaması.....	23
1.4.3. Değişim (Varyasyon) Katsayısı	25

İKİNCİ BÖLÜM

YAPAY SİNİR AĞLARI

2.1. Yapay Sinir Ağları.....	27
2.2. Biyolojik Sinir Hücresi.....	28
2.3. Yapay Sinir Hücresi ve Temel Elemanları	29
2.3.1. Girdi Değerleri	29
2.3.2. Ağırlıklar	29
2.3.3. Toplama Fonksiyonu	29
2.3.4. Aktivasyon Fonksiyonu	30
2.3.5. Hücrenin Çıktısı	31
2.4. Yapay Sinir Ağlarının Avantajları ve Dezavantajları.....	32
2.4.1. Doğrusal Olmama	32

2.4.2. Öğrenme.....	32
2.4.3. Genelleme Yapabilme.....	32
2.4.4. Uyarlanabilirlik.....	33
2.4.5. Hata Toleransı ve Esneklik.....	33
2.4.6. Paralel Çalışma.....	33
2.4.7. Hafıza.....	33
2.4.8. Sınırsız Sayıda Değişken ve Parametre Kullanımı.....	33
2.4.9. Kendi İlişkisini Oluşturma.....	34
2.5. Yapay Sinir Ağlarının Sınıflandırılması.....	34
2.5.1. Katman Sayısına Göre Yapay Sinir Ağları.....	34
2.5.1.1. Tek Katmanlı Yapay Sinir Ağları.....	34
2.5.1.2. Çok Katmanlı Yapay Sinir Ağları.....	35
2.5.2. Bağlantı Yapısına Göre Yapay Sinir Ağları.....	37
2.5.2.1. İleri Beslemeli Yapay Sinir Ağları.....	37
2.5.2.2. Geri Beslemeli Yapay Sinir Ağları.....	38
2.5.3. Öğrenme Şekline Göre Yapay Sinir Ağları.....	39
2.5.3.1. Danışmanlı Öğrenme.....	39
2.5.3.2. Danışmansız Öğrenme.....	40
2.5.3.3. Destekleyici Öğrenme.....	40
2.6. Öğrenme Kuralları.....	41
2.6.1. Hebb Kuralı.....	41
2.6.2. Hopfield Kuralı.....	41
2.6.3. Delta Kuralı.....	41
2.6.4. Kohonen Kuralı.....	42
2.6.5. Eğimli İniş Kuralı.....	42
2.7. Yapay Sinir Ağlarının Uygulama Alanları.....	42
2.8. Hisse Senetlerinin Fiyat Tahmini İçin Yapay Sinir Ağları ile Yapılan Çalışmalar.....	43

ÜÇÜNCÜ BÖLÜM

BİST ELEKTRİK ENDEKSİNDE YER ALAN ŞİRKETLERİN HİSSE SENEDİ FİYAT TAHMİNİNDE YAPAY SİNİR AĞLARI UYGULAMASI

3.1. Çalışmanın Amacı ve Önemi.....	51
3.2. Veri ve Değişkenler	52
3.3. Analiz Yöntemi ve Yapay Sinir Ağları Modellerinin Oluşturulması.....	55
3.4. Analiz Sonuçları	58
3.4.1. Ham Veriler İçin %80 Eğitim %20 Test Oranına Göre Sonuçlar.....	58
3.4.2. Ham Veriler İçin %90 Eğitim %10 Test Oranına Göre Sonuçlar.....	63
3.4.3. Normalizasyon Yapılmış Veriler İçin %80 Eğitim %20 Test Oranına Göre Sonuçlar	68
3.4.4. Normalizasyon Yapılmış Veriler İçin %90 Eğitim %10 Test Oranına Göre Sonuçlar	74
3.5. Genel Değerlendirme.....	91
SONUÇ.....	94
KAYNAKÇA	96
EKLER.....	104

SİMGELER VE KISALTMALAR LİSTESİ

ABD	: Amerika Birleşik Devletleri
AKENR	: Akenerji Elektrik Üretim Anonim Şirketi
AKSUE	: Aksu Enerji ve Ticaret Anonim Şirketi
AYEN	: Ayen Enerji Anonim Şirketi
BİST	: Borsa İstanbul
BR	: Bayesian Regularization Algoritması
İMKB	: İstanbul Menkul Kıymetler Borsası
LM	: Levenberg-Marquardt Algoritması
MAD	: Mean Absolute Deviation (Ortalama Mutlak Sapma)
MAE	: Mean Absolute Error (Ortalama Mutlak Hata)
MAPE	: Mean Absolute Percentage Error (Ortalama Mutlak Yüzde Hata)
MSE	: Mean Squared Error (Ortalama Kare Hata)
NARX	: Doğrusal Olmayan Otoregresif Eksojen Modeli
R²	: The Coefficient of Determination (Belirleme Katsayısı)
RMSE	: Root Mean Squared Error (Ortalama Hata Karelerinin Karekökü)
SCG	: Scaled Conjugate Gradient (Ölçekli Eşlenik Gradyan) Algoritması
TDK	: Türk Dil Kurumu
TÜFE	: Tüketici Fiyat Endeksi
TÜİK	: Türkiye İstatistik Kurumu
TWh	: Terawatt Saat
XELKT	: BİST ELEKTRİK Endeksi
VAR	: Vektör Otoregresyon Modeli
VC	: Değişim (Varyasyon) Katsayısı
YSA	: Yapay Sinir Ağları
ZOREN	: Zorlu Enerji Elektrik Üretim Anonim Şirketi

TABLÖLER LİSTESİ

Tablo 1.1:	A Firmasının Hisse Senedine Ait Beklenen Getiri Hesaplaması	22
Tablo 1.2:	A Firmasının Hisse Senedine Ait Risk Hesaplaması	23
Tablo 1.3:	B Firmasına Ait Hisse Senedinin Getirileri	24
Tablo 1.4:	A Hisse Senedine Ait Tarihsel Veriler	25
Tablo 1.5:	A Hisse Senedinin Risk Hesaplaması	25
Tablo 1.6:	X ve Y Hisse Senedi için Beklenen Getiri ve Risk Tablosu	26
Tablo 2.1:	Bazı Toplama Fonksiyonları	30
Tablo 2.2:	Yaygın Kullanılan Aktivasyon Fonksiyonları	31
Tablo 2.3:	Biyolojik Sinir Sistemi Elemanları ve Yapay Sinir Sisteminde Karşılıkları	32
Tablo 3.1:	Analizdeki Hisse Senetlerine Ait Endeks Adı-Şirket Unvanları ve Kodlar	55
Tablo 3.2:	Yapay Sinir Ağı Modeli ile İlgili Bilgiler	57
Tablo 3.3:	AKENR Hisse Senedi Analiz Sonucu	58
Tablo 3.4:	AKSUE Hisse Senedi Analiz Sonucu	59
Tablo 3.5:	AYEN Hisse Senedi Analiz Sonucu	60
Tablo 3.6:	ZOREN Hisse Senedi Analiz Sonucu	61
Tablo 3.7:	XELKT Endeksi Analiz Sonucu	62
Tablo 3.8:	Ham Veriler İçin %80 Eğitim %20 Test Oranına Göre En İyi Analiz Sonuçları	63
Tablo 3.9:	AKENR Hisse Senedi Analiz Sonucu	63
Tablo 3.10:	AKSUE Hisse Senedi Analiz Sonucu	64
Tablo 3.11:	AYEN Hisse Senedi Analiz Sonucu	65
Tablo 3.12:	ZOREN Hisse Senedi Analiz Sonucu	66
Tablo 3.13:	XELKT Endeksi Analiz Sonucu	67
Tablo 3.14:	Ham Veriler İçin %90 Eğitim %10 Test Oranına Göre En İyi Analiz Sonuçları	68
Tablo 3.15:	AKENR Hisse Senedi Analiz Sonucu	69
Tablo 3.16:	AKSUE Hisse Senedi Analiz Sonucu	70
Tablo 3.17:	AYEN Hisse Senedi Analiz Sonucu	71
Tablo 3.18:	ZOREN Hisse Senedi Analiz Sonucu	72
Tablo 3.19:	XELKT Endeksi Analiz Sonucu	73

Tablo 3.20. Normalizasyon Yapılmış Veriler İçin %80 Eğitim %20 Test Oranına Göre En İyi Analiz Sonuçları.....	73
Tablo 3.21: AKENR Hisse Senedi Analiz Sonucu	74
Tablo 3.22: AKSUE Hisse Senedi Analiz Sonucu.....	75
Tablo 3.23: AYEN Hisse Senedi Analiz Sonucu	76
Tablo 3.24: ZOREN Hisse Senedi Analiz Sonucu.....	77
Tablo 3.25: XELKT Endeksi Analiz Sonucu	78
Tablo 3.26. Normalizasyon Yapılmış Veriler İçin %90 Eğitim %10 Test Oranına Göre En İyi Analiz Sonuçları.....	78
Tablo 3.27. Normalizasyon Yapılmış Veriler İçin %80 Eğitim %20 Test Oranı ve %90 Eğitim %10 Test Oranına Göre En İyi Analiz Sonuçlarının Karşılaştırılması	79

ŞEKİLLER LİSTESİ

Şekil 1.1: Pazar Modeli ve Betalar	6
Şekil 1.2: Risk Bileşenleri	7
Şekil 1.3: Toplam Riskin Kaynakları	8
Şekil 1.4: Paralel Kayıtsızlık Eğrileri	16
Şekil 1.5: Risk – Getiri Kayıtsızlık Eğrileri.....	16
Şekil 1.6: Risk Karşısında Yatırımcı Tipleri	18
Şekil 1.7: Riski Seven Yatırımcı.....	19
Şekil 1.8: Riske Kayıtsız Yatırımcı	19
Şekil 1.9: Riskten Kaçan Yatırımcı	20
Şekil 1.10: Riskleri Kabullenme İsteğine Göre Yatırımcı Tipleri	20
Şekil 2.1: Biyolojik Sinir Hücresinin Yapısı	28
Şekil 2.2: Yapay Bir Sinir Ağı Yapısı	29
Şekil 2.3: Basit Algılayıcı	30
Şekil 2.4: Tek Katmanlı Yapay Sinir Ağları.....	35
Şekil 2.5: Çok Katmanlı Bir Yapay Sinir Ağı	35
Şekil 2.6: İleri Beslemeli Bir Yapay Sinir Ağı Mimarisi	37
Şekil 2.7 : Geri Beslemeli Ağ Yapısı.....	38
Şekil 2.8 : Danışmanlı- Öğretmenli Öğrenme	39
Şekil 2.9 : Danışmansız- Öğretmensiz Öğrenme	40
Şekil 2.10: Destekleyici- Takviyeli Öğrenme.....	41
Şekil 3.1: XELKT Endeksi Yapay Sinir Ağı Yapısı	80
Şekil 3.2: XELKT Endeksi Performans Grafiği	80
Şekil 3.3: XELKT Endeksi Hata Histogram Grafiği	81
Şekil 3.4: XELKT Endeksi Regresyon Grafiği	81

Şekil 3.5: AKENR Hisse Senedi Yapay Sinir Ağı Yapısı.....	82
Şekil 3.6: AKENR Hisse Senedi Performans Grafiği.....	83
Şekil 3.7: AKENR Hisse Senedi Hata Histogram Grafiği.....	83
Şekil 3.8: AKENR Hisse Senedi Regresyon Grafiği.....	84
Şekil 3.9: AKSUE Hisse Senedi Yapay Sinir Ağı Yapısı	84
Şekil 3.10: AKSUE Hisse Senedi Performans Grafiği	85
Şekil 3.11: AKSUE Hisse Senedi Hata Histogram Grafiği	85
Şekil 3.12: AKSUE Hisse Senedi Regresyon Grafiği	86
Şekil 3.13: AYEN Hisse Senedi Yapay Sinir Ağı Yapısı.....	86
Şekil 3.14: AYEN Hisse Senedi Performans Grafiği	87
Şekil 3.15: AYEN Hisse Senedi Hata Histogram Grafiği	87
Şekil 3.16: AYEN Hisse Senedi Regresyon Grafiği.....	88
Şekil 3.17: ZOREN Hisse Senedi Yapay Sinir Ağı Yapısı	89
Şekil 3.18: ZOREN Hisse Senedi Performans Grafiği	90
Şekil 3.19: ZOREN Hisse Senedi Hata Histogram Grafiği	90
Şekil 3.20: ZOREN Hisse Senedi Regresyon Grafiği	91

GİRİŞ

Teknolojideki hızlı gelişim insanların yaşamlarına da yansımıştır. Öyle ki bundan 20-30 sene öncesine kadar cep telefonları sadece haberleşme amacıyla kullanılırken günümüzde ise bu cep telefonları çeşitli mühendislik programlarının kullanılabildiği, adres tarifi yapabilen, istenildiği zaman araştırma yapılabilen mini bilgisayarlar konumundadır. Aynı şekilde arabaları düşündüğümüzde de elektrikle çalışabilen, sürücünün konforu düşünülerek uzaktan bir komut ile araçta telefon görüşmelerinin yapılabilmesi, sürücüsünün müdahalesine gerek olmadan kendi kendine park edebilen arabalar yoğun ilgi gören ve günlük hayatta teknolojinin insana getirdiği kolaylıklardan sadece birkaçıdır. Tüm bu imkânlar düşünüldüğünde insanın öğrenme, düşünme, karar verme, hatırlama gibi özelliklerinin bilgisayar programları ile makinelerle verilmesi sonucu yapay zekâ kavramı oluşmuştur. Yapay zekânın, günümüzde birçok alanda görebildiğimiz ve her geçen gün yeni bir şeyler eklenerek kendini geliştiren bir alan olduğu görülmektedir. Diğer taraftan bu durum enerji tüketimini de artırmakta, enerji kaynaklarının da anlam ve önemini göstermektedir. Özellikle elektrik enerjisi tüm teknolojik cihazlar için hayati önem taşımaktadır. Elektrik enerjisinde dışa bağımlılığın azaltılması, temiz enerji ve sürdürülebilirliğin elde edilebilmesi için yenilenebilir enerji alanları tüm dünyada olduğu gibi ülkemiz için de önemli bir konu olmuştur. Elektrik üretiminin güneş, rüzgâr, biyokütle gibi yenilenebilir kaynaklardan sağlanabiliyor olması yatırımcılarında ilgisini çekmektedir. Bu durum enerji şirketlerinin de artmasına sebep olmuştur. Bu şirketlerin borsada halka arz olması hisse senedi yatırımcılarının da ilgisini çekmektedir. Diğer taraftan hisse senetlerinde riskin yüksek olması ve geleceğe yönelik belirsizlik durumu yatırımcıların hangi finansal aracı seçmesi gerektiği konusunda kafa karışıklığı yaratabilmektedir. Bu sebeple yatırımcıların seçtikleri hisse senedinin getirilerini öngörebilmeleri o hisse senedine yatırım yapıp yapmamaları konusunda yardımcı olacaktır. Bu konuda literatürde yapılan çalışmalar incelendiğinde Yapay Sinir Ağları'nın başarılı bir performans gösterdiği görülebilmektedir.

Bu çalışmada uzun dönemde Yapay Sinir Ağları Yönteminin başarısını incelemek amacıyla 20 yıllık bir dönem için analiz yapılmıştır. Literatürdeki ulaşılabilen araştırmalara bakıldığında yapay sinir ağları ile hisse senedi fiyat tahmini konusunda birçok araştırma bulunmaktadır. Yine literatürden ulaşılabildiği kadarıyla, BİST Elektrik Endeksi fiyat tahmininin bazı makroekonomik göstergelerin bağımsız değişken olarak ele alındığı farklı yapay sinir ağları modelleri oluşturularak yapılmış herhangi bir çalışmaya rastlanmamıştır. Bu sebeple BİST Elektrik Endeksi hisse senetlerinin fiyatları Yapay Sinir Ağları (YSA) yöntemiyle tahmin edilmeye çalışılmıştır. Çalışmada 2004- 2024 yılları için Euro, Dolar, Gram Altın, Brent Petrol, Tüketici Fiyat Endeksi (TÜFE) ve BİST100 endeksi verileri bağımsız değişkenler olarak kullanılmış olup, BİST Elektrik Endeksi ve Akenerji, Aksu Enerji, Ayen Enerji ve Zorlu Enerji hisse senetleri ise bağımlı değişken olarak seçilmiş ve MATLAB programı vasıtasıyla gerekli analizler yapılmıştır. Analizler sonucunda gerçek fiyat ile ulaşılan fiyat arasındaki fark Ortalama Kare Hata (MSE) ölçütü ile incelenmiştir.

Çalışma üç bölümden oluşmaktadır. Birinci bölümde yatırım kavramı, yatırımcı türleri, toplam riskin kaynakları, hisse senetleri için risk ve getiri hesaplamaları anlatılmıştır. İkinci bölümde YSA ile ilgili bilgiler, YSA'nın avantaj ve dezavantajları, katman sayıları, bağlantı yapıları ve öğrenme şekillerine göre YSA'lardan bahsedilmiştir. Ayrıca literatür değerlendirmesi de bu bölümde yer almaktadır. Üçüncü bölümde analiz yöntemi, verileri ve YSA modelleri açıklanarak analiz sonuçlarının değerlendirilmesi, ulaşılan analiz sonuçlarına ait tablo ve şekilleri yer alacaktır.

BİRİNCİ BÖLÜM

YATIRIM KAVRAMI VE RİSK KARŞISINDA YATIRIMCILARIN TÜRLERİ

1.1. Yatırım Kavramı

Yatırım kavramı gerek kişiler gerekse firmalar açısından çeşitli sebeplerden dolayı önemlidir. Bireyler açısından incelendiğinde, gelirinden bir kısmını harcamadan gelecekte daha fazla kazanç sağlamak ve buna bağlı olarak daha fazla harcama yapabilmek adına çeşitli finansal varlıklara yatırım yapan kişiler bugünkü harcamalarından fedakârlık yapmaktadır. İşletmeler açısından bakıldığında ise firmalar, rekabet ettiği işletmelerin de içinde bulunduğu pazardaki paylarını artırabilmeleri, içinde bulundukları sektör için önemli olan teknolojik gelişmeleri takip edebilmeleri, üretim yapan firmaların üretim kapasitelerini artırmaları ve üretim faaliyetlerini sürdürebilmeleri gibi nedenlerden dolayı yatırım yapmaktadır. Bu açıdan bakıldığında yapılan yatırımdan zarar edilmesi, yatırımı yapan kişiler ve işletmeler için büyük bir maliyete sebep olmaktadır. Bu nedenle yapılacak yatırımın iyi ve doğru bir şekilde değerlendirilmesi gerekmektedir.

Yatırım kavramıyla ilgili literatürde birçok tanım yer almaktadır. Yatırım kavramı, işletme ve ekonomi bilimleri için farklı anlamlara sahiptir. Buna göre ekonomi biliminde yatırım, belirli bir dönemde üretilmiş malların tüketilmeyen bölümü olarak tanımlanır (Aktaş vd., 2017, s. 286). Başka bir açıklamada ise işletmelerin mal ve hizmet üretebilmesi için stok, makine, fabrika gibi sermaye unsurlarına harcamalar yapılması yatırım olarak ifade edilmiştir (Yıldırım vd., 2013, s. 383).

Türk Dil Kurumu sözlüğü (TDK, 2020), yatırımı; ulusal ekonominin ya da bir işletmenin üretim ve hizmet gücünü artıracak özellikteki aktif değerlere yapılan ilâveler ve “Parayı, gelir getirici, taşınır veya taşınmaz bir mala yatırma, mevduat, plasman.” şeklinde tanımlar.

Aktaş ve diğerleri (2017, s. 287), işletme biliminde yatırımın tanımını, firma bilançosunda yer alan aktiflerin toplamı olarak kabul edenler olduğu gibi paranın farklı bir üretim faktörüne

dönüşmesi şeklinde açıklayanların olduğunu ifade etmiştir. Ayrıca yatırımın, kişiler açısından gelir ya da verim sağlamak için tasarrufların kullanılması olarak da tanımlandığını belirtmiştir.

Yatırım kelimesi “Nakdi sermayeye gelir sağlamak” şeklinde tanımlanmış ve “Özellikle, sermaye piyasalarının geliştiği ülkelerde gelir getirmeyen nakdi varlığın daha az likit aktiflere çevrilerek geri getirmesi sağlanır.” açıklaması yapılmıştır (Mucuk, 2014, s. 78).

Aksoy ve Tanrıöven (2014, s. 1), sonraki dönemlerde daha çok harcama yapabilmek için şimdiki harcamalardan fedakârlık yapmanın yatırım olarak açıklanabileceğini belirtmiştir. Karan (2018, s. 3) ise yatırımı, gelecekte daha çok getiri sağlayabilmek için bir miktar parayı bir işe bağlamak olarak ifade etmiştir. Buna benzer şekilde başka bir açıklama da Bodie ve diğerleri (2018, s. 2) tarafından yapılmış, hâlihazırda bulunan para ve benzeri fonların daha sonraki dönemlerde daha çok faydaya ya da kaynağa ulaşabilme düşüncesiyle şimdiden transfer edilmesi yatırım kavramı olarak belirtilmiştir.

Korkmaz ve Ceylan (2017, s. 16) ise “Yatırımcı, belli bir getiri sağlamak amacıyla, belirli vadelerde birikimlerini yatırım araçlarına bağlayan kişidir.” açıklamasıyla yatırımın, ek bir getiri elde etmek için belirli bir süreliğine, gelirin tüketilmeyen kısmıyla yatırım araçları alınması olduğunu ifade etmişlerdir.

Tüm bu açıklamalar göz önünde bulundurulduğunda yatırım kavramı, bireylerin ya da işletmelerin elde ettikleri gelirlerin bir bölümünü daha fazla gelir sağlamak ve buna bağlı olarak daha fazla harcama yapabilmek amacıyla gayrimenkullere veya finansal varlıklara dönüştürmesi olarak açıklanabilir.

Yatırımlar, yatırım yapılan kaynakların nitelikleri ve yatırım yapılan varlığın vadesi gibi özelliklere göre gruplandırılabilir. Buna göre yatırım yapılan kaynakların nakde dönüştürülmesi bir yıldan uzun bir vadede gerçekleşiyorsa buna sabit (duran) varlıklara yatırımlar, bir yıl ve bir yıldan daha az bir zaman içinde birçok kere nakde dönüştürülebiliyorsa dönen varlıklara yatırım olarak belirtilir. Yine aynı şekilde yatırım yapılan varlıklarla yatırımın vadesi birbirleri ile ilgilidir. Uzun vadeli yatırımlar duran varlıklara yapılan yatırımlar olarak bilinirken, kısa vadeli yatırımlarda dönen varlıklara yapılan yatırımlar olarak ifade edilmektedir (Aksoy & Tanrıöven, 2014, s. 3).

1.2. Toplam Riskin Kaynakları

“Zarara uğrama tehlikesi, riziko.” (TDK, 2020) risk kavramı olarak tanımlanmaktadır. Aktaş ve diğerleri (2017, s. 337)’e göre risk kavramının tanımı; yatırım yapılan finansal araçların

gerçekleşmesi beklenen getirisinin belirsizlik durumu ya da beklenenden az getiri sağlanması ihtimalidir. Buna göre finans biliminde risk, yatırım yapılan finansal varlığın ilerideki dönemlerdeki getirilerinin tahmin edilememesi ya da yatırım yapılan finansal varlığın ulaşılan getirisinin beklenen getiriden farklı olma durumudur.

Beklenen getiriden fazla getiriye ulaşmak, yatırım yapılan varlığın riski değil potansiyeli olarak açıklanmaktadır. Buna bağlı olarak yatırımın riski arttığında getirisi artarken, beklenen getiriden fazla elde edilen kazanç ise finansal varlığın potansiyelini artırmaktadır (Dayı, 2017, ss. 79-80).

Yatırımcılar için yatırım yaptıkları finansal varlıkların getirileri ve riskleri önemlidir. Yatırımcılar bir yandan finansal varlığın getirisinin fazla olmasını isterken diğer taraftan da daha az risk alarak bu getiriye sağlamak isterler. Bu nedenle, finansal araçları etkileyen risk türlerinin ve bu risklerin nasıl azaltılabileceğinin yatırımcı tarafından bilinmesi yatırım için oluşturulan portföylerde daha az risk oluşmasını sağlayacaktır.

Yapılan yatırımlardaki riskler, yatırımcıların kontrol edebilmeleri ya da bu riskleri sınırlayabilme durumlarına göre iki çeşittir (Yıldırım, 2019, s. 422). Bunlardan biri yatırım yapılan finansal aracın içinde yer aldığı pazar, enflasyon, faiz oranı gibi makroekonomik unsurların etkisini ifade eden sistematik risklerdir (Akagün, 2006, s. 2). Sistematik olmayan risk ise firmaya veya firmanın içinde yer aldığı endüstriye ait risklerdir (Kalfa, 2010, s. 12). Buna göre; sistematik ve sistematik olmayan risklerin toplamından oluşan toplam risk şu formülle gösterilebilir (Korkmaz & Ceylan, 2017, s. 610):

$$\sigma_i^2 = \beta_i^2 \sigma_m^2 + \sigma_e^2$$

Formüle göre:

σ_i^2 : Finansal aracın toplam riskini,

β_i^2 : Finansal aracın sistematik riske duyarlılığını,

σ_m^2 : Sistematik riski,

σ_e^2 : Sistematik olmayan riski ifade etmektedir.

Burada finansal varlığın sistematik riske duyarlılığı beta katsayısı ile ölçülmektedir. Okka (2015, s. 268), beta katsayısını şu şekilde anlatmaktadır: “**Beta katsayısı**; bir varlığın getirisinin, pazarın getiri oranının değişikliğine karşı göstermiş olduğu tepkilerin bir göstergesi yani endeksiydi. Diğer bir ifadeyle **beta**; bir varlığın ortalama bir varlığa (pazara)

göre ne kadar saptığını, farklı davranış gösterdiğini ortaya koyuyordu.” Çeşitlendirilemeyen risk olarak da bilinen sistematik riskin ölçülmesinde kullanılan beta katsayısı, Sermaye Varlıklarını Fiyatlama Modeli’nde şu şekilde hesaplanmaktadır (Korkmaz, 2013, s. 22):

$$\beta_i = \frac{COV(r_i, r_m)}{\sigma_m^2}$$

Formüle göre:

β_i : i hisse senedinin betası,

r_i : i hisse senedinin beklenen getirisi,


r_m : Pazar portföyünün getirisi,

$COV(r_i, r_m)$: i hisse senedinin ve pazar portföyünün getirisi arasındaki kovaryans veya ortak değişkenliği,

σ_m^2 : Pazar portföyünün varyansını göstermektedir.

Bu hesaplamanın sonucunda $\beta < 1$ ise hisse senedi, piyasadaki değişikliklere daha az duyarlıdır yani sistematik risk düşüktür. $\beta > 1$ olduğunda hisse senedi, piyasadaki değişikliklerden daha fazla etkilenmekte, yani sistematik risk yüksektir. $\beta = 1$ ise hisse senedi ve piyasadaki değişiklikler aynı oranda etkilenir ve orta dereceli risktir. $\beta = 0$ olduğunda hisse senedinin risksiz getiri oranında verim sağladığı belirtilmiştir (Aksoy & Tanrıöven, 2014, s. 716).

Şekil 1.1: Pazar Modeli ve Betalar



Kaynak: Karan (2018, s. 228).


Buna göre sistematik ve sistematik olmayan risklerden oluşan toplam risk formülü şu şekilde gösterilebilir (Akagün, 2006, s. 2):

Toplam Risk = Sistematik Risk + Sistematik Olmayan Risk

$$\sigma_i^2 = \beta_i^2 \sigma_m^2 + \sigma_{ei}^2$$

Toplam riskin bileşenleri aşağıdaki şekilde gösterilebilir.

Şekil 1.2: Risk Bileşenleri




Kaynak: Korkmaz & Ceylan (2017, s. 611).

Şekil 1.2.'de görüldüğü gibi sistematik risk, aynı seviyede yer almaktadır. Bunun anlamı sistematik riskin asla yok edilemeyeceğidir. Fakat sistematik risk daima aynı seviyede sabit kalmaz. Yapılan portföy yatırımlarına göre sistematik riskin düzeyi daha yüksek ya da daha az olabilir. Bu duruma örnek olarak yalnızca bir ülkedeki finansal araçlardan oluşan bir portföyle uluslararası sermaye piyasalarında yer alan finansal araçlardan oluşan portföyler gösterilebilir. Uluslararası sermaye piyasalarında yer alan finansal araçlardan oluşan portföylerin sistematik riski diğer portföyün sistematik riski ile aynı değildir (Korkmaz & Ceylan, 2017, ss. 611-612). Yatırımcılar, riski azaltmak amacıyla farklı ülkelerin yatırım araçlarına, farklı sektörlerde faaliyet gösteren firmalara ve farklı finansal varlıklara yatırım yapabilirler. Aynı şekilde yatırım yapacakları firmanın gelişmişlik seviyesini araştırarak teknolojik gelişmelere uyum sağlayabilmesi, yönetim şekli, firmanın faaliyet gösterdiği sektörün o dönemdeki finansal durumu gibi firmanın kendisine ve içinde bulunduğu endüstri alanına ait özellikler düşünülerek yatırım yapılması da yatırımın sistematik olmayan riskinin azaltılması ve hatta iyi bir şekilde değerlendirme yapıldığında yok edilmesi konusunda

önemlidir. Bu konudaki düşüncesini Kalfa, (2010, s. 13) “Sistematik riskin kontrol edilmesi imkânsızken, sistematik olmayan riskin kaynaklarında yapılan değişmelerle ve yönlendirmelerle kontrol edilmesi ve yok edilmesi mümkündür.” cümlesiyle açıklamıştır.

Yatırımcılar, portföylerde yapılan çeşitlendirmeler sayesinde yani yatırım için ayrılan tutarın çeşitli varlıklar arasında dağıtılmasıyla riski bir miktar azaltabilecektir. Yapılan çeşitlendirme ile beklenen getiri düzeyinde azalma olmaksızın riskin azaltılması, portföydeki bazı varlıkların verimlerindeki azalmanın portföyde yer alan diğer varlıkların verimlerindeki artışla karşılanma imkânından kaynaklanmaktadır. Buna sebep, sistematik olmayan risklerin firmaya veya firmanın içinde yer aldığı sektöre ait riskler olduğu için tüm finansal varlıkları etkilememesidir (Dramalija, 2008, s. 70). Sistematik ve sistematik olmayan riskleri oluşturan riskler Şekil 1.3’de gösterilmektedir.

Şekil 1.3: Toplam Riskin Kaynakları



Kaynak: Korkmaz ve Ceylan (2017, s. 611).

Yatırım yapan bireylerin ve firmaların, yatırımın getirisiyle ilgili bilgi sahibiyken yatırımın riskleriyle ilgili yeterli bilgiye sahip olduklarından söz edilemez. Ancak yatırımcı için risk kaynakları ve türleri önemlidir. Yapılan yatırımın sistematik ve sistematik olmayan unsurlarının portföylerdeki miktarı belirlenip buna göre portföyler hazırlanabilir (Metin, 2017, s. 12).

1.2.1. Sistematik Risk

Portföyde yapılan çeşitlendirme sonucunda kalan risk piyasanın tamamına etki eden risk olan piyasa riskidir. Yani tüm ekonomiye etki eden risk unsurları piyasa riski, sistematik risk ya da çeşitlendirilemez risk olarak adlandırılır (Bodie vd., 2018, s. 149). Sistematik risk “Bütün yatırım araçlarının verimliliklerini etkileyen ekonomik, politik ve diğer çevre şartlarında ki

değişmelerin getirdiği risklerdir.” (Aksoy & Tanrıöven, 2014, s. 34). Portföylerdeki varlıkların çeşitlendirilmesi ile yok edilemeyen ancak bütün varlıkları aynı düzeyde etkilemeyen risklerdir. Buna örnek olarak temel sanayi ürünleri üreten firmaların pay senetlerinde sistematik riskin daha fazla etkili olduğu belirlenmiştir (Alekberv, 2001, s. 8).

Sarılı (2014, s. 6), sistematik riskin; politik, sosyal, ekonomi gibi bir ekonomik sistemdeki herkesi etkileyen durumlardan etkilendiğini ifade etmiştir. Bu risk türlerinden risk yönetimi sayesinde kaçınılabileceği fakat beklenilenin dışında gerçekleşen durumlarda karşı karşıya kalınan risklerin sadece etkilenme düzeyinin azaltılabileceğini açıklamıştır. Sistematik riske 1994’deki ekonomik kriz örnek gösterilebilir (Şentürk, 1997, s. 26).

Gelişmiş ülkelere göre gelişmekte olan ülkelerdeki toplam riskin içinde yer alan sistematik risk oranı daha yüksektir. ABD’de 63 şirket ile yapılan bir araştırmada toplam riskin içerisindeki sistematik riskin %33 oranında olduğu belirtilmiştir (Aksoy & Tanrıöven, 2014, s. 34). 1987’de İMKB’de yer alan 28 firmanın olduğu bir araştırmada sistematik riskin %65,5 olduğu belirtilmiştir (Aktaran: Zengin, 2006, s. 30).

Makroekonomik faktörler olan döviz kuru, enflasyon ve faiz oranı ve enerji kaynaklarının maliyetlerinde gerçekleşen değişimlerin şirketler üzerinde etkisi bulunmaktadır. Tüm bu faktörler makro olaylar olup bu makro riskler olumsuz ise pay senetleri fiyatları azalacak, olumlu ise artacaktır (Dramalija, 2008, s. 61).

Yapılmış çalışmalar, rassal seçilen 15-20 yatırım araçlarından oluşan portföylerde sadece sistematik riskin olduğunu böylece olabilecek en az risk düzeyinin elde edilebildiğini açıklamaktadır (Aktaran: Akagün, 2006, s. 3).

Satın alma gücü (enflasyon) riski, faiz oranı riski, piyasa riski, kur riski ve politik risk sistematik riski oluşturmaktadır.

1.2.1.1. Satın Alma Gücü (Enflasyon) Riski

TDK (2024), enflasyonu; “Dolanımdaki para miktarıyla, malların ve satın alınabilir hizmetlerin toplamı arasındaki açığın büyümesinden ortaya çıkan ve fiyatların toplam yükselişi, paranın değerinin düşmesi biçiminde kendini gösteren ekonomik parasal süreç; para şişkinliği, parasal şişkinlik.” şeklinde tanımlamaktadır. Böylece enflasyondaki sürekli artış, kullanılan para biriminin satın alma gücünün azalmasına sebep olmaktadır.

Bono, tahvil gibi finansal araçların getirisi de enflasyon oranının artmasıyla birlikte azalacaktır. Portföyünde hazine bonosu bulunduran yatırımcılar bu hazine bonosunu elinde

bulundurduğu vadedeki enflasyon oranını bilemeyeceği için hazine bonosunda da enflasyon riski bulunmaktadır (Yıldırım, 2019, ss. 423-424). Diğer taraftan hisse senetleri ve tahvillerde enflasyon riskinden etkilenir. Ancak tahviller hisse senetlerine göre enflasyon riskinden daha çok etkilenir. Bunun nedeni, enflasyon artışının hisse senetlerine sahip firmaların ürün fiyatlarında artışı beraberinde getirmesi ve böylece kâr payı dağıtımında da bir artış yaşanacak olmasıdır (Alekberv, 2001, ss. 8-9). Fakat enflasyon nedeniyle maliyetlerin de yükselmesi artan kârı dengeleyerek enflasyonun hisse senetleri üzerindeki etkisini azaltmaktadır. Enflasyon oranına diğer finansal varlıklara göre en az duyarlılık gösteren varlıklar hisse senetleridir (Akagün, 2006, s. 5). Enflasyon oranının yüksek olmasının yarattığı belirsizlik hisse senetlerini negatif yönde etkilemektedir (Yıldırım, 2019, s. 424).

1.2.1.2. Faiz Oranı Riski

Faiz oranlarında karşılaşılan dalgalanmalar nedeniyle yapılan yatırımların getirilerinde oluşabilecek değişiklikler faiz oranı riski olarak tanımlanmaktadır. Şentürk (1997, s. 26), piyasada bulunan bütün finansal varlıkların getirilerinin faiz oranındaki değişime duyarlı olduğunu belirtmiştir. Faiz oranı riskinden en fazla etkilenen finansal varlıklar; tahviller, vadeli banka mevduatları, hazine bonoları gibi sabit getiri sağlayan yatırım araçları olmakla birlikte hisse senetleri de faiz oranındaki değişimlere duyarlılık göstermektedir (Alekberv, 2001, s. 9).

Ülkemizde tahviller 1980'e kadar sabit faiz ile ihraç edilmiş, enflasyonun yükselmesi ile tahvil ihraç eden şirketler kâr elde etmişlerdir. Fakat enflasyonist dönemlerde yatırım kararlarında zararlarla karşılaşan yatırımcılar tahvillere yatırım yapmaktan vazgeçmiştir. Bunun nedeni tahvil, bono gibi varlıkların belirli bir faiz oranı üzerinden sabit getiri elde etmesidir. Diğer yandan hisse senetlerinde ise sabit getiriden söz edilemez. Burada hisse senedi yatırımcısı için önemli olan hisse senedinden beklediği getirinin, faiz oranından fazla olmasıdır (Korkmaz & Ceylan, 2017, s. 618).

Faiz oranında meydana gelen artış, sabit getiriye sahip yatırım araçlarının fiyatının azalmasına dolayısıyla yatırımda zarar edilmesine sebep olur (Dramalija, 2008, s. 65). Faiz oranları azaldığında ise yatırım yapılan finansal varlıkların fiyatları yükselecektir.

Yatırımcılar, kısa vadeli tahvillere yatırım yaparak faiz oranı riskinden kaçınabilirler. Ancak kısa vadeli tahvillere yatırım yaptıktan sonra yine kısa vadeli finansal varlıklara yatırım yapma durumunda olmaları faiz oranı riskinden kurtulma ihtimallerini azaltır. Aynı zamanda yatırımcılarda, ilerdeki dönemler için faiz oranında büyük farklılıklar olacağı beklentisi varsa

hisse senetlerine yatırım yapmak faiz oranı riskinin azalmasını sağlayabilir (Korkmaz & Ceylan, 2017, ss. 618-619).

1.2.1.3. Piyasa (Pazar) Riski

Finansal piyasalarda, belli bir sebepten dolayı bazen de herhangi bir geçerli neden bulunmasa bile yatırım araçlarının fiyatlarında ciddi düşüşler olabilir. Bu durum piyasa (pazar) riskini oluşturmaktadır (Aktaş vd., 2017, s. 339).

Petrol, altın vb. artan üretimi, ülkede seçim yapılacak olması, başlayan veya biten bir savaş gibi tüm ülkeyi etkileyen ve olağan dışı durumlar yatırımcılar açısından belirsizlik oluşturur böylece yatırımcının piyasadan kaçışına sebep olur (Yıldırım, 2019, s. 424).

Hisse senedi, tahvil gibi sabit getiriye sahip varlıklara göre piyasa riskinden daha fazla etkilenmektedir (Zengin, 2006, s. 33). Alekberov (2001, s. 10), bunun hisse senetlerine göre tahvil fiyatlarının tahmin edilmesinin güç olmasından kaynaklandığını açıklamıştır. Piyasadaki olumsuz bir durum hisse senetlerinin fiyatlarını da olumsuz etkileyecek buna bağlı olarak hisse senetlerinin fiyatında ve piyasa değerinde düşüş olacaktır (Dayı, 2020, s. 4).

Yatırımcılar pazar riskini azaltmak için portföyüne dahil etmeyi düşündüğü hisse senedi değerinin, piyasanın değişimlerden nasıl etkilendiğini belirleyebilmek için duyarlılığı olarak ifade edilen beta katsayısını hesaplamalıdır (Dramalija, 2008, s. 68).

Akagün (2006, s. 4), pazar (piyasa) riskinden korunmanın birkaç yolunu şu şekilde sıralamıştır:

- Geçmiş dönemlerdeki hisse senedi fiyat hareketlerini inceleyerek ilerdeki dönemlerin fiyat hareketlerini tahmin etmek.
- Teknik ve temel analiz metotları ile hisse senetlerini alış-satış dönemini belirlemek.
- En az piyasa riskine sahip hisse senetlerini almak.
- Yatırımın uzun ya da kısa vadeli olacağının belirlenmesi gerekir. Piyasa riski için kısa vadeli yatırımlara nazaran uzun vadeli yatırım yapan yatırımcılar aylık, günlük, haftalık değişimlere karşı daha az duyarlıdır.

1.2.1.4.Döviz Kuru Riski

Döviz kurlarında oluşabilecek değişimler sonucu oluşan belirsiz ortam sebebiyle meydana gelen, yabancı para birimiyle yapılan yatırımları ve yabancı ülkelere yapılan yatırımları etkileyen risk türüdür (Aksoy & Tanrıöven, 2014, s. 40).

“Satın Alma Gücü Paritesi Teorisine göre kurlardaki değişimlerle değişik ülkelerdeki faiz oranları arasında sıkı bir ilişki var. Kurlardaki değişimlere paralel olarak yatırımcı ülkelerde yapılan yatırımların karlılık oranları değişecektir.” (Alekberv, 2001, s. 10). Diğer taraftan, döviz kurlarında sürekli meydana gelen değişimler, yabancı ülkelerdeki finansal varlıkları portföyüne dahil eden yatırımcının her zaman kazanacağı veya kaybedeceği gibi bir durum ifade etmemektedir. Aynı zamanda döviz kurlarındaki yükseliş yerli para biriminin değerinde azalmaya böylece de pay senetlerinin getirisinde azalmaya neden olacaktır (Yıldırım, 2019, ss. 424-425).

Dramalija (2008, s. 69), yatırımcıların döviz riskini azaltabilmek amacıyla farklı ülkelerin finansal varlıklarına yer verdikleri portföyler oluşturabileceklerini anlatırken; Dayı (2020, s. 4), “Yatırımcılar, şirketler ve hatta devletler döviz kuru riskine karşı vadeli işlemler piyasasında pozisyon alarak riski minimize edebilirler.” ifadesiyle döviz kuru riskinin azaltılabileceğini belirtmiştir.

1.2.1.5. Politik Risk

Ülkelerin, politikalarında meydana gelen değişimlerin finansal varlıkların getirisi üzerindeki etkisine politik risk denir. “Politik riskler ise, piyasa riski ile iç içedir. Genellikle siyasal ortamlardaki gerginliklerden kaynaklanır. Özellikle politik istikrarsızlık en büyük nedenidir.” (Dörtbölük, 2019, s. 41). Ülkelerdeki savaşlar, ekonomik ve siyasi bunalımlar yatırım yapacak birey ve firmaların davranışlarında etkiye sahiptir. Uluslararası ticaret, politik riskin başka boyutu olarak tanımlanabilir. Kotalar, döviz kurundaki dalgalanmalar, gümrük vergilerinde artış olması ve benzeri durumlar bu riskin unsurlarıdır. (Aktaş vd., 2017, ss. 339-340).

Politik riskin arttığı yerlerde, piyasada durgunluk oluşabilir ve böylece pay senetlerinin getirileri azalabilir (Aktaş vd., 2017, s. 340). Politik riski azaltmak amacıyla yatırımcılar, portföylerini oluştururken çoğunlukla gelişmiş ülkelerin piyasalarına yönelmektedir (Dayı, 2020, s. 4). Saleck (2018, s. 37), politik riskle ilgili: “Gelişmekte olan ülkelerin dış yatırım eksikliği yaşamasının büyük bir sebebidir. Politik ve ekonomik sistemleri dünyadaki en kararlı sistem olduğu için Birleşik Devletler en düşük ülke riskine sahip olan ülke olarak

kabul edilir.” açıklamasını yapmıştır. Ayrıca 1998’de yaşanan döviz krizi ve devlet statüsünde gerçekleştirilen birkaç değişiklikler nedeniyle Rusya; isyanların, gösterilerin ve 1998’e kadar yapılan işten çıkarmaların olduğu Endonezya politik riski yüksek ülkelere örnektir (Saleck, 2018, s. 37).

1.2.2. SistematiK Olmayan Risk

Daha önce açıklandığı gibi toplam riski oluşturan sistematiK riskler, makroekonomik faktörlerden oluştuğu için çok iyi bir portföy çeşitlendirmesi yapılsa dahi asla yok edilememekte, yalnızca riskin düzeyi azaltılabilmektedir. SistematiK olmayan riskler ise firma, endüstri gibi mikroekonomik faktörlerden oluştuğu için iyi bir çeşitlendirme sayesinde azaltılabilir. Bu sebepten sistematiK olmayan riske çeşitlendirilebilir risk de denilmektedir.

Harry Markowitz, portföy için seçilecek finansal araçların getirileri arasında tam pozitif korelasyona sahip olmayan varlıkların yer almasının getiriye azaltmadan sistematiK olmayan riski düşürebileceğini savunmuştur. Bu aynı zamanda Modern Portföy Teorisini oluşturmaktadır (Aktaş vd., 2017, s. 350). SistematiK olmayan risk; finansal risk, iş ve endüstri riski ve yönetim riskinden oluşmaktadır.

1.2.2.1. Finansal Risk

Finansal risk; firmaların finansal yükümlülüklerini yerine getirememesi, borçlarını ödemede yetersiz kalması gibi finansal açıdan karşılaşılabileceği olumsuz koşullar olarak tanımlanabilir. Şirketlerin borçlarının miktar olarak gelirlerinden fazla olması bu firmanın finansal riskinin de fazla olduğunu yani çevresel ve ekonomi ile ilgili şartlara adapte olamaması buna bağlı olarak da faiz ve anapara ödemelerini yapamayacak durumda olma tehlikesini göstermektedir (Aktaş vd., 2017, s. 341).

Şentürk (1997, s. 27), finansal riskin şirkete özgü bir risk olduğunu ve likidite ihtiyacı, borç miktarı, satışlardaki stabilizasyon, rekabet ve grevler gibi unsurlarla doğrudan ilişkili olduğunu ifade etmiştir. Bu risk türünde, firmada finansal olarak herhangi bir problem yokken, finansal borç kaldıraç görevi yaparak kârları artırırken, finansal olumsuzluklar olduğunda firmanın borç ödeyebilme yeteneği azalır ve yükümlülüklerini yerine getiremeyebilir (Yıldırım, 2019, s. 425).

Şirketlerin borç yapısı konusunda izledikleri yol, faiz oranı, finansal kararları finansal harcamalarını oluşturmaktadır. Borçlanarak finansmanın kaldıraç etkisini kullanmayı düşünen şirket paydaşları finansal risklere açıktır (Kayahan, 2019, s. 155).

Hisse senetleri, tahvillere göre finansal risklere daha çok duyarlıdır. Bunun nedeni tahvilin yatırımcısına sağladığı haklar nedeniyle tahvilin faiz ödemelerinin zamanında ödenme zorunluluğu bulunurken, hisse senetlerinde ise faiz ödemelerinin miktarı dağıtılacak temettü miktarını etkilemektedir. (Aksoy & Tanrıöven, 2014, s. 43; Korkmaz & Ceylan, 2017, s. 621). Kayahan (2019, ss. 155-156), yüksek finansal kaldıraç derecesine sahip şirketlerin finansal riskinin de yüksek olduğunu ifade ederek finansal kaldıraç derecesinin aşağıdaki gibi hesaplandığını belirtmiştir:

$$\text{Finansal Kaldıraç Derecesi} = \frac{\Delta HBK}{HBK} / \frac{\Delta F.V.Ö.K}{F.V.Ö.K} \text{ veya } \frac{M * (F - B.D.G) - S.G}{M * (F - B.D.G) - (S.G + C)}$$

Birinci formülde:

ΔHBK : Hisse Başına Kazançtaki Değişim

HBK : Hisse Başına Kazanç

$\Delta FVÖK$: Faiz ve Vergi Öncesi Kârdaki Değişim

$FVÖK$: Faiz ve Vergi Öncesi Kârdır.

Diğer formülde ise:

M : Miktar,

$S.G$: Sabit Gider,

$B.D.G$: Birim Değişir Gider,

C : Finansman Gider

F : Fiyatı ifade etmektedir.

Finansal risk, özel kamu ayrımı olmaksızın tüm kuruluşlarda bulunmakta ancak devlet garantisi olmasından dolayı kamu kuruluşlarında daha az olmaktadır. Ayrıca finansmanını özkaynak ile sağlayan şirketlerin ihraç ettiği finansal varlıklara yapılan yatırım finansal riski yok edebilir (Yıldırım, 2019, ss. 425-426).

1.2.2.2. Yönetim Riski

Şirket yöneticilerinin iyi ya da hatalı karar almaları şirketleri ve dolayısıyla bu şirketlerin ihraç ettikleri finansal varlıkların getirilerini de etkilemektedir. Şentürk (1997, s. 27) Yönetim riskinin, şirketin yönetim hatalarından kaynaklanan risk olduğunu anlatmıştır. Yönetim riskinden hisse senedi yatırımcıları tahvillere yatırım yapan yatırımcılardan daha çok

etkilenmektedir. Bu sebeple de şirket yöneticilerinin kalitesi, tecrübe ve başarı gibi özellikleri önemlidir (Aktaş vd., 2017, ss. 341-342). Başarılı bir yönetici bir firmadan başka bir firmaya transfer olduğunda, geldiği firmanın hisse senedi fiyatlarında artış görülebilir (Yıldırım, 2019, s. 425).

1.2.2.3. İş ve Endüstri Riski

Bu risk türü aynı endüstride bulunan şirketlerle ilgili olup bir sektöre ait pazarda oluşabilecek fiyat iniş çıkışlarının neden olduğu risktir (Aleksberov, 2001, s. 11). Yani o endüstri içinde yer almayan şirketler bu riskten etkilenmezler.


Yerli hammadde kullanan bir sektöre göre hammaddenin yurtdışından temin edildiği sektördeki endüstri riski daha fazladır. Aynı zamanda demir, un, kömür gibi ürünlere talebin daha az değişiklik göstermesi bu sektörde faaliyet gösteren endüstri riskini diğer sektörlerle göre daha azaltmaktadır (Aktaran: Kalfa, 2010, s. 14).

1.3. Kayıtsızlık (Farksızlık) Eğrileri

Kayıtsızlık eğrileri, çeşitli finansal araçlardan oluşan portföylerin getiri ve risk kriterlerine göre hangi portföy seçeneğinin yatırımcı açısından daha kârlı olduğunu gösteren eğrilerdir. Karan (2018, s. 173), kayıtsızlık eğrilerinin grafiğinde x ekseninin portföy riskini, y ekseninin ise portföyün beklenen getirisini gösterdiğini belirterek kayıtsızlık eğrilerinin özelliklerini şu şekilde sıralamıştır:

- Kayıtsızlık eğrileri hiçbir zaman birbirlerini kesmez.
- Kayıtsızlık eğrilerinin daha yukarda (kuzeybatıda) olanı diğer kayıtsızlık eğrilerine göre daha çok tercih edilir.
- Bir kayıtsızlık eğrisi üzerindeki tüm portföyler eşit faydaya sahiptir.
- Farksızlık eğrisinin eğiminin yönü sağ tarafa gittikçe risk fazla olmasına rağmen getiri azalacaktır.

Şekil 1.4: Paralel Kayıtsızlık Eğrileri




Kaynak: Karan (2018, s. 175).

Daha önce açıklanan kayıtsızlık (farksızlık) eğrilerinin özellikleri göz önünde bulundurulduğunda Şekil 1.4.'de A ve B portföyleri eşit faydaya sahiptir. D faydası en fazla portföyken C portföyünün faydasının en az olduğu görülmektedir.

Yatırımcıların risk karşısındaki tutumlarına göre kayıtsızlık eğrileri de farklılık göstermektedir. Bununla ilgili grafikler aşağıda gösterilmektedir.

Şekil 1.5: Risk – Getiri Kayıtsızlık Eğrileri



Kaynak: Karan(2018, s. 174).

Şekil 1.5.'teki grafiklerde eğrinin eğiminin artması yatırımcının riskten kaçındığını göstermektedir. Diğer yandan "r" risksiz faiz miktarını ifade etmektedir. İki yatırımcı tipi de r miktarındaki getiriye risksiz şekilde ulaşmaktadır. Fakat risk arttıkça getirinin de daha çok olması istenmektedir. Bu durumda risk seven yatırımcı alacağı riske göre daha az getiri, riskten kaçınan yatırımcı ise alacağı riske göre daha çok getiri beklentisinde olacaktır (Karan, 2018, s. 173).

1.3.1. Fayda Fonksiyonu ve Risk Karşısında Yatırımcı Tutumları

Yatırımcılar için yapacakları yatırımın ve oluşturacakları portföylerin risk ve getirileri çok önemlidir. Yatırımcıların aldıkları riske göre yatırımlarının daha az getiri sağlaması istenmeyen bir durumdur. Bununla birlikte yatırımın sağladığı getiriye göre riskin az olması da yatırımcının hedefini oluşturmaktadır. Yatırımcıların getiri ve risk değerine göre yatırımlarını portföy seçeneklerinin risk ve getirilerine göre daha kârlı olan portföyden daha az kârlı portföye kadar sıralamasını sağlayan fayda fonksiyonu bulunmaktadır.

Aşağıda fayda fonksiyonunun formülü ve bir örneği yer almaktadır (Korkmaz & Ceylan, 2017, s. 594):

$$F = E(R) - 0,005 \cdot A \cdot \sigma^2$$

Bu formüle göre:

F : Faydayı,

E(R) : Yatırımın beklenen getirisini,

A : Yatırımcının riskten kaçınma derecesini,

σ^2 : Yatırımın varyansını ifade etmektedir.

Örneğin, bir hisse senedinin yıllık beklenen getirisi %19, standart sapması %22 olsun. Risksiz devlet tahvilinin beklenen getirisinin %13, risksiz olduğu için de standart sapmasının sıfır olduğu ve yatırımcının risk sevmeyişi varsayılarak riskten kaçınma derecesinin 3 olarak belirlendiği bilindiğine göre her iki yatırım için fayda fonksiyonu şöyledir:

Risksiz devlet tahvilinin fayda fonksiyonu:

$$E(R) - 0,005 \cdot A \cdot \sigma^2 = F$$

$$13 - (0,005 \cdot 3 \cdot (0^2)) = \%13$$

Hisse senedinin fayda fonksiyonu:

$$E(R) - 0,005 \cdot A \cdot \sigma^2 = F$$

$$19 - (0,005 \cdot 3 \cdot (22)^2) = \%11,74$$

Örnekte de görüldüğü gibi riskin artması fayda değerini azaltmaktadır. Beklenen getiri ise fayda değerini artırmaktadır. Ancak burada yatırımcının riskten kaçınma derecesi de önemlidir. Riskten kaçınma derecesi 2 veya 1 olsaydı yani yatırımcı diğer örneğe göre risk seven bir

yatırımcı olsaydı fayda değeri daha çok artacak, riskli yatırım daha fazla tercih edilebilir olacaktı (Korkmaz & Ceylan, 2017, ss. 594-595).

Yatırımcının riskten kaçınma derecesi 1 ve 2 olduğunda yatırımın fayda değeri şu şekildedir:


$$F = 19 - (0,005 \cdot 2 \cdot (22)^2) = \%14,84$$

$$F = 19 - (0,005 \cdot 1 \cdot (22)^2) = \%16,58$$

1.3.2. Yatırımcı Türleri

“Yatırımcılar, verimliliğin kendilerine sağlayacağı faydayı dikkate alarak, faydanın ölçüsü oranında verimlilik için riske katlanma, kayıtsız olma ve riskten kaçma gibi üç değişik davranış içerisinde bulunurlar.” (Aksoy & Tanrıöven, 2014, s. 14).

Şekil 1.6: Risk Karşısında Yatırımcı Tipleri




Kaynak: Korkmaz & Ceylan (2017, s. 595).

1.3.2.1. Risk Seven Yatırımcı

Yatırımcılar için yatırımın riskinin getirisinden yüksek olmasının istenmeyen bir durum olduğu düşünüldüğünde tüm yatırımcıların riskten kaçındığı bir gerçektir. Ancak yatırımcı türlerine göre bu riskten kaçınma derecesinde farklılıklar vardır. Bu yatırımcı türlerinden biri, diğerlerine göre daha çok risk alan yani risk seven yatırımcılardır. Risk ve getiri arasında doğrusal bir ilişkinin bulunduğu göz önünde bulundurulduğunda riski yüksek bir yatırımın getirisinin de yüksek olacağı düşünülmektedir.

Yatırımcılar için yatırım yapmamanın beklenen faydası, yapılacak yatırımın beklenen faydasından daha düşüktür. Bundan dolayı bu yatırımcılar için risk primi sıfır veya sıfırdan daha düşük düzeydedir (Korkmaz & Ceylan, 2017, s. 597). Risk seven yatırımcılar için fayda-verimlilik grafiği aşağıdaki gibidir.

Şekil 1.7: Riski Seven Yatırımcı



Kaynak: Korkmaz & Ceylan (2017, s. 597).


Riskten kaçmayan yatırımcılar için her ek ünite elde edilen verimliliğin sağlayacağı fayda da artacaktır (Aksoy & Tanrıöven, 2014, s. 14). Şekil 1.7.'de görüldüğü gibi bu tür yatırımcıların fayda- verimlilik grafiğinde marjinal fayda birden büyük olmaktadır.

Çakar ve Özkan (2019, s. 35), riskten kaçan ve risk seven yatırımcılar için portföy oluşturulabilecek piyasaların araştırıldığı bir çalışmanın sonucunda riskten kaçmayan yatırımcılar için belirlenen 20 ülke arasından en yüksek riskli ülke endekslerinin içinde ilk sırada Venezuela, ikinci sırada Arjantin ve üçüncü sırada Kazakistan olduğunu belirlemişlerdir. En düşük riskli ülke endekslerinin ise sırasıyla Lübnan, Ürdün ve Bosna Hersek olduğunu ifade etmişlerdir. Risk seven yatırımcılar için çalışmada belirlenen 20 ülke endeksinin gelişmekte olan piyasa endeksleri olduğu belirtilmiştir.

1.3.2.2. Riske Kayıtsız Yatırımcı

Bu yatırımcılar için yatırımdan beklenen getiri yatırım kararlarını etkilemekte, risk ise yapılacak yatırımın yönünü etkileyecek öneme sahip olmamaktadır. Yani bu yatırımcılar riskle ilgilenmemektedir. Riske kayıtsız yatırımcılar için fayda fonksiyonunda riskten kaçınma derecesi olarak tanımlanan $A=0$ 'dır (Korkmaz & Ceylan, 2017, s. 596).

Şekil 1.8: Riske Kayıtsız Yatırımcı




Kaynak: Korkmaz & Ceylan (2017, s. 596).

Riske kayıtsız yatırımcıların her ek ünite elde ettiği verimliliğin sağlayacağı fayda birbirine eşit olacağı için marjinal fayda eğimi 1'e eşit olmaktadır (Aksoy & Tanrıöven, 2014, s. 14).

1.3.2.3. Riskten Kaçan Yatırımcı

Yatırımcıların birçoğu rasyonel olmaları nedeniyle riskten kaçmaktadır. Riskten kaçan yatırımcılar risk almaktan korkan, riski sevmeyen yatırımcılardır. Bu sebeple, getirileri belli olan yatırımlardan riski daha az olanı tercih ederler. Bu yatırımcılar için risk priminin sıfırdan yüksek olması gerekir. Riskten kaçan yatırımcının her ek ünite elde edeceği verimliliğin faydası azalarak devam eder. Bu tür yatırımcılar için paranın marjinal faydası negatif eğime sahiptir (Korkmaz & Ceylan, 2017, s. 596).


Şekil 1.9: Riskten Kaçan Yatırımcı



Kaynak: Korkmaz & Ceylan (2017, s. 596).

Yatırımcıların tüm bu özellikleri dikkate alındığında oluşturacakları portföylerin yapılarının da farklı olabileceği görülmektedir. Portföylerin birden fazla finansal araçlarla oluşturulması, yatırımcıların risk tutumlarına göre oluşturdukları portföylerde her bir finansal varlığa farklı oranlarda yer vermesine neden olmaktadır.

Şekil 1.10: Riskleri Kabullenme İsteğine Göre Yatırımcı Tipleri



Kaynak: Korkmaz (2013, s. 83).

Şekil 1.10.'da görüldüğü gibi riskten kaçan yatırımcıların portföylerini büyük bir bölümünü düşük riskli olan tahvil, hazine bonosu gibi varlıklar oluştururken; risk seven yatırımcıların portföyleri büyük oranda hisse senetlerinden meydana gelmektedir. Riske karşı kayıtsız yatırımcıların portföylerini eşit oranlardaki tahvil ve hazine bonosu ile hisse senetleri oluşturmaktadır (Korkmaz, 2013, s. 82). Yatırım yapan kişi ve firmaların genellikle riskten kaçınan yatırımcı tiplerinde olduğunu söyleyebiliriz. Bu sebeple riski fazla olan yatırımlar yapmak için alınacak riskten daha fazla getiri sağlamayı istemektedirler. Bu durum, firmaların atılımcı yaklaşım yerine muhafazakâr yaklaşımda olarak firmanın dengeli büyümesini sağlar (Okka, 2015, s. 250).

1.4. Beklenen Getiri ve Risk Hesabı

Yatırımcılar, yatırım yaptıkları finansal varlığın en az riskle en fazla getiriye sağlamasını isterler. Ancak yatırım yaptıkları varlığın hangi miktarlardaki getiriye ne kadar bir riskle elde edeceğini belirlemeleri gerekir. Finans biliminde risk kavramı varyans ve standart sapma ile ölçülmektedir. Bunun amacı beklenen getiri ile gerçekleşebilecek olan getiri arasındaki olabilecek farkın mümkün olduğunca doğru bir şekilde saptanmasını ve elde edilen sonuca göre hisse senedi seçiminin yapılmasını sağlamaktır. Diğer taraftan az önce belirtildiği gibi iki farklı getiriden bahsedilebilir. Bunlardan biri yatırım yapılan finansal varlığın belirli bir dönem için gerçekleşen getirisi, diğeri ise gelecek dönemler için beklenen getirisidir.

Bir dönem için hesaplanan getiri oranı, hisse senedinin dönem başı piyasa fiyatının dönem sonu piyasa fiyatından çıkarılmasıyla elde edilen sonucun dönem başı fiyata bölünmesidir. Bir dönemlik getiri oranı ile yatırımcının servetinin artış hızı belirlenmektedir (Yıldırım, 2019, s. 412). Aksoy ve Tanrıöven (2014, s. 450) hisse senetleri için bir dönemlik getiri oranını şu şekilde göstermiştir:

$$r_{HS} = \frac{(P_t - P_{t-1}) + T_t}{P_{t-1}}$$

r_{HS} : Hisse senedinden elde edilen getiri oranını,

P_{t-1} : Hisse senedinin t-1 dönemindeki alış fiyatını,

P_t : Hisse senedinin t dönemindeki satış fiyatını,

T_t : Hisse senedinin elde tutulan dönemdeki temettü ödemesini ifade etmektedir.

Beklenen getiri oranı ise gerçekleşen getiriyi değil gelecek dönemler için beklenen getiri miktarını göstermektedir. Beklenen getiri olasılık dağılımı ve tarihsel verilerin yardımıyla olmak üzere iki şekilde hesaplanmaktadır.

1.4.1. Olasılık Dağılımı ile Beklenen Getiri ve Risk Hesaplaması

Hisse senetleri sermaye piyasasında yer alan yatırım araçlarından biridir. Hisse senedine yatırım yapan yatırımcılar, hisse senedini ihraç eden şirketlere aldıkları hisse kadar ortak olmaktadır. Ayrıca hisse senetleri yatırımcısına şirket yönetimiyle ilgili kararlarda oy kullanma, bilgi alma, kâr payı alma, şirketi denetleme ve inceleme, tasfiye bakiyesine katılma, rüçhan hakkı ve bedelsiz pay alma gibi haklar sağlamaktadır (Aksoy & Tanrıöven, 2014, s. 421).

Yatırımcılar tarafından hisse senedine yapılan yatırımın getirisinin yüksek olması amaçlanmaktadır. Bu sebeple de yatırımcının, belirlediği firmanın veya firmaların hisse senedine yatırım yapmadan önce bu firmaların geçmiş dönemlerdeki hisse senedi hareketleri takip etmesi olası bir zararı engellemek adına önemli bir adımdır. Bir hisse senedi için farklı periyotlardaki veya koşullardaki getiri olasılıkları yardımıyla beklenen getiri hesaplanabilmektedir. Örneğin A firmasına ait hisse senedinin beklenen ekonomik koşullardaki olasılıkları ve getiri oranları Tablo 1.1.'de gösterildiği gibidir.

Tablo 1.1: A Firmasının Hisse Senedine Ait Beklenen Getiri Hesaplaması

Ekonomik Durum	Olasılık (P_i)	Getiri Oranı (r_i)	Beklenen Getiri ($\bar{r}$)
Durgunluk	%8	-0,09	-0,0072
Zayıf	%14	0,10	0,014
Orta	%30	0,17	0,051
İyi	%43	0,27	0,1161
Çok İyi	%5	0,33	0,0165

Beklenen getiri, her bir dönem için belirlenen olasılık ve getiri oranının çarpımlarının toplanması sonucu elde edilen değerdir. Yukarıdaki örnek için olasılık ve getiri oranının çarpımı sonucunda ulaşılan değerler toplandığında A firmasının hisse senedinin beklenen getirisi %19,04 olarak hesaplanmaktadır.

Yatırım ile ilgili bir diğer önemli kavram da risktir. Yatırımcının yaptığı yatırımdan kazanç sağlayamaması, zarar etmesi riski de bulunmaktadır. Finansta riskin ölçüsü standart sapma veya onun karesi alınarak hesaplanan varyanstır. Varyans veya standart sapmanın küçük olması yatırımın riskinin az olduğunu, büyük olması ise riskin çok olduğunu ifade etmektedir.

Varyans; $\sigma^2 = \sum_{j=1}^n (r_j - \bar{r})^2 p_j$ formülü ile hesaplanmaktadır (Karan, 2018; s. 143). Bu formüle

göre her bir dönem için gerçekleşen getiriden beklenen getirinin çıkarılması sonucunda ulaşılan değerin karesinin alınıp ilgili dönem için belirtilen olasılıkla çarpımlarının toplamı varyansı, toplamının karekökü ise standart sapmayı oluşturmaktadır. Buna göre önceki örnekteki hisse senedinin risk hesaplaması şu şekilde olmalıdır:

Tablo 1.2: A Firmasının Hisse Senedine Ait Risk Hesaplaması

Getiri (r_i)	Beklenen Getiri ($\bar{r}$)	($r_i - \bar{r}$)	($r_i - \bar{r}$) ²	Olasılık (P_i)	$\sigma^2 = (r_i - \bar{r})^2 \cdot P_i$
-0,09	0,1904	-0,2804	0,0786	0,08	0,006288
0,10	0,1904	-0,0904	0,0082	0,14	0,001148
0,17	0,1904	-0,0204	0,0042	0,30	0,00126
0,27	0,1904	0,0796	0,00634	0,43	0,00273
0,33	0,1904	0,1396	0,01949	0,05	0,00098

Her bir dönem için hesaplanan varyanslar toplandığında A hisse senedinin riski, varyans olarak $\sigma^2 = 0,012$; standart sapma olarak ise $\sigma = \sqrt{0,012} = 0,1095$ bulunmaktadır.

1.4.2. Tarihsel Veriler Yardımı ile Beklenen Getiri ve Risk Hesaplaması

Bundan önceki anlatılan hesaplamalar yapılacak yatırımın hangi olasılıkla ne kadar getiri sağlayacağını belirlenmesiyle yapılabilir. Ancak bunun yanında ilgili hisse senedinin geçmiş dönemlerdeki getirileri yardımıyla da beklenen getiri ve risk hesaplanabilir. Bu amaçla, belirlenen hisse senedinin geçmiş ay veya yıl gibi periyotlara ait getirilerine ulaşılarak hesaplamalar yapılır. Hisse senedinin geçmiş dönemlerdeki getirilerinin ortalaması alınarak ortalama getirisi hesaplanır. Yıldırım (2019, ss. 412-413) ortalama getiriye, aritmetik ortalama olarak bilinen tüm dönemlere ait getirilerin toplamının dönem sayısına bölünmesiyle veya her bir döneme ait getirinin “1” ile toplamının birbirleri ile çarpımı sonucu ulaşılan değerin dönem sayısı kadar kökü alınarak elde edilen geometrik ortalamasıyla ulaşılabileceğini ve geometrik ortalama ile hesaplanan ortalama getirinin uzun dönem ortalama getiri hesaplamalarında daha doğru sonuçlar verdiğini ifade etmektedir. Aritmetik ve geometrik ortalama formülleri şu şekilde gösterilmektedir (Yıldırım, 2019, s. 413):

$$\text{Aritmetik Ortalama: } \bar{r}_t = \frac{(r_1 + r_2 + \dots + r_n)}{n}$$

$\bar{r}_t$ = Getirinin aritmetik ortalaması,

r_1 = Birinci dönemdeki getiri oranı,

r_2 = İkinci dönemdeki getiri oranı,

r_n = n. dönemdeki getiri oranı,

n = Dönem miktarıdır.

$$\text{Geometrik Ortalama: } 1 + \bar{r}_t = \sqrt[n]{\prod_{t=1}^n (1 + r_t)}$$

Örneğin B hisse senedine ait geçmiş 5 yıllık getiriler aşağıdaki gibidir:

Tablo 1.3: B Firmasına Ait Hisse Senedinin Getirileri

Dönem	2015	2016	2017	2018	2019
Getiri	0,15	0,28	0,22	0,31	0,29

Tüm bu bilgilere göre B hisse senedinin ortalama getirisi aritmetik ortalama hesabına göre:

$$\bar{r}_t = \frac{(0,15) + (0,28) + (0,22) + (0,31) + (0,29)}{5} = 0,25 = \%25$$

Geometrik ortalama hesabına göre ise:

$$\bar{r}_t + 1 = \sqrt[5]{(1 + 0,15)(1 + 0,28)(1 + 0,22)(1 + 0,31)(1 + 0,29)} = 0,2486 = \%24,86 \text{ olarak hesaplanır.}$$

Korkmaz ve Ceylan (2017, s. 382) tarihi verilerin getirilerinin ortalaması hesabında kullanılan aritmetik ve geometrik ortalama yöntemleriyle ilgili olarak 20 yıla kadarki periyotlar için aritmetik ortalamanın, 20 yıldan 40 yıla kadarki periyotlar için iki yönteminde kullanılabileceğini ifade etmişlerdir. 40 yıl ve daha uzun periyotlar için ise geometrik ortalamanın kullanılması önerilmiştir (Aktaran: Korkmaz & Ceylan, 2017, s. 382). Tarihi verilerden yararlanarak hesaplanan risk şu şekildedir (Karan, 2018, s. 145):

$$\sigma = \sqrt{\sum_{t=1}^n (r_t - r_{ort})^2 / n - 1}$$

n = Zamandır.

Yukarıdaki formülde bir hisse senedinin risk hesaplamasında geçmişteki her bir dönemde gerçekleşen getiriden ortalama getiri çıkarılarak elde edilen sonucun karesi alınır. Bu işlem, hesaplanması istenen tüm dönemler için yapılarak ulaşılan sonuçlar toplanır ve son olarak kaç

dönem için hesaplama yapılacaksa bir eksiğine bölünür. Bu hesaplama hisse senedinin varyansını ifade etmektedir. Bulunan sonucun karekökü ise standart sapmasını gösterir.

Tablo 1.4: A Hisse Senedine Ait Tarihsel Veriler

Dönem	2013	2014	2015	2016	2017	2018	2019	2020
Getiri	-0,20	0,07	0,15	0,21	0,17	0,19	0,25	0,20

Yukarıdaki tabloda bir hisse senedinin yıllara göre elde ettiği getiriler yer almaktadır. Bu verilere göre getirilerin aritmetik ortalama yöntemiyle hesaplanan ortalama getirisi 0,13 olarak bulunmuştur.

Tablo 1.5: A Hisse Senedinin Risk Hesaplaması

Dönem	Getiri	$(r_t - r_{ort})^2$
2013	-0,20	0,1089
2014	0,07	0,0036
2015	0,15	0,0004
2016	0,21	0,0064
2017	0,17	0,0016
2018	0,19	0,0036
2019	0,25	0,0144
2020	0,20	0,0049

Tüm bu hesaplamalara göre tarihsel verileri verilen bir hisse senedinin varyansı:

$$\sigma^2 = \sum_{t=1}^n (r_t - r_{ort})^2 / n - 1 \text{ formülüne göre } 0,1438 / (8 - 1) = 0,0205 ; \text{ standart sapması ise}$$

$$\sigma = \sqrt{0,0205} = 0,1432 \text{ olarak bulunmuştur.}$$

1.4.3. Değişim (Varyasyon) Katsayısı

Finansal araçların risk karşılaştırmasında kullanılan bir yöntemde değişim katsayısıdır. Yatırımcının portföyüne dahil etmeyi düşündüğü finansal araçların risk analizinde kullanılmaktadır. Karan (2018, s. 146), değişim katsayısı hesabının ilgili finansal varlığın standart sapmasının beklenen getiriye oranı olduğunu $VC = \sigma / \bar{r}$ formülüyle ifade etmiştir. Aynı standart sapma ve varyansta olduğu gibi değişim katsayısının da hesaplanan değeri hangi finansal araç için düşük ise o yatırım aracının riski düşüktür. Yıldırım (2019, s. 418), varyans ve standart sapma ile varyasyon katsayısı arasındaki farkı “Varyans ve standart sapma yatırımın riskini mutlak değer olarak ölçer. Başka bir yatırımlarla karşılaştırma yapabilmek için nispi değerlere ihtiyaç duyulur.” açıklamasıyla anlatmış; değişim katsayısı

veya diğ er ismi ile varyasyon katsayısını bir finansal varlığın sağladığı bir birim getiride karşılaştığı risk ölçüsü olarak tanımlamıştır.

Tablo 1.6: X ve Y Hisse Senedi için Beklenen Getiri ve Risk Tablosu

X Hisse Senedinin Beklenen Getirisi	X Hisse Senedinin Standart Sapması	Y Hisse Senedinin Beklenen Getirisi	Y Hisse Senedinin Standart Sapması
0,14	0,22	0,25	0,38

Tablodaki bilgilere göre X hisse senedi için değ işim katsayısı: $\frac{0,22}{0,14} = 1,57$ 'dir. Y hisse

senedi için ise $\frac{0,38}{0,25} = 1,52$ 'dir. Tablodaki veriler incelendiğinde X hisse senedi Y hisse

senedine göre daha az riskli ancak daha az getiriye sahiptir. Fakat değ işim katsayısına göre baktığımızda Y hisse senedi X' e göre daha az riskli olmaktadır.

İKİNCİ BÖLÜM

YAPAY SİNİR AĞLARI

2.1. Yapay Sinir Ağları

Teknolojinin gelişmesiyle birlikte bilgisayar teknolojilerinin hayatımızdaki yeri ve önemi de büyük ölçüde artmıştır. İnsanlar günlük yaşamda yaptığı birçok işte bilgisayar teknolojilerinden faydalanmaktadır. İnsanın düşünme, öğrenme, karar verme, hatırlama gibi özelliklerinin bilgisayar programları ile makinelere verilmesi sonucu yapay zekâ kavramı oluşmuştur. Yapay zekâ günümüzde akıllı telefonlardan, robot süpürgelere, otomobillere kadar birçok alanda görebildiğimiz ve her geçen gün yeni bir şeyler eklenerek kendini geliştiren bir alan olmuştur. Yapay sinir ağları ise yapay zekânın bir alanını oluşturmaktadır. Yapay sinir ağları, insan beyninin işleyiş biçiminden yola çıkılarak oluşturulan ve bu sayede makinelere insanlarda olduğu gibi dışarıdan gelen bilgileri hafızaya alma, öğrenme ve karar verme gibi özellikleri kazandıran sistemlerdir.

Yurtoğlu (2005, s. 4), yapay sinir ağlarıyla ilgili şu ifadeleri kullanmıştır:

Yapay Sinir Ağları, basit biyolojik sinir sisteminin çalışma şeklini simüle etmek için tasarlanan programlardır. Simüle edilen sinir hücreleri (nöronlar) içerirler ve bu nöronlar çeşitli şekillerde birbirine bağlanarak ağı oluştururlar. Bu ağlar öğrenme, hafızaya alma ve veriler arasındaki ilişkiyi ortaya çıkarma kapasitesine sahiptirler.

Sevinçtekin (2014, s. 6) ise yapay sinir ağını “Yapay sinir ağı; insan beyninin sinir hücrelerinden oluşmuş katmanlı ve paralel olan yapısının tüm fonksiyonlarıyla beraber sayısal dünyada gerçekleştirilmeye çalışılan modellenmesidir. Sayısal dünya ile belirtilmek istenen donanım ve yazılımdır.” şeklinde tanımlamış ve yine aynı çalışmasında yapay sinir ağlarının olayların örneklerini inceleyerek bununla ilgili


genelleme yaptığını buna bağlı olarak da hiç karşılaşmadığı örneklerde daha önceden öğrendiği bilgileri kullanarak karar alabildiğini açıklamıştır.

Yapılan araştırmalarda, yapay sinir ağlarının biyolojik sinir ağının bir taklidi olduğu ifade edilmektedir.

2.2. Biyolojik Sinir Hücresi

İnsan beyni, “nöron” isimli çok sayıdaki ve birbirine bağlı sinir hücrelerinden oluşmaktadır (Tektaş & Karataş, 2004, s. 338). Şekil 2.1.’de biyolojik bir sinir hücresinin yapısı gösterilmektedir.

Şekil 2.1: Biyolojik Sinir Hücresinin Yapısı



Kaynak: Yazar (2004, s. 17).


Sinir hücresi; sinaps, dentrit, hücre gövdesi (soma) ve akson denilen dört bölümden oluşmaktadır. Dentrit, sinaps vasıtasıyla başka bir sinir hücresinin aksonundan gelen elektrik akımını hücre gövdesine aktarır. Hücre gövdesi, hücreye iletilen tüm elektrik sinyallerini toplar ve hücrenin eşik değeri geçilmişse aksonda bir elektrik akımı gerçekleşerek bu akım başka bir hücrenin dentritine yine sinapslar yardımıyla iletilir (Bayır, 2006, ss. 16-17).

İnsanlar, yaşayarak öğrenme sürecindeyken beyin de daima bir gelişme göstermektedir. İnsanların yaşamda elde ettikleri tecrübeler sonucu sinir hücrelerine yer alan sinaptik bağlantılar ayarlanırken yeni sinaptik bağlantılar da oluşabilir. Böylece öğrenme gerçekleşir. Yapay sinir ağlarında da öğrenme girdi verileri ve çıktı verilerinin eğitilmesiyle, bağlantı ağırlıkları en yakın sonucu verinceye kadar sürekli olarak ayarlanmaktadır (Yurtoğlu, 2005, s. 5).

2.3. Yapay Sinir Hücresi ve Temel Elemanları

Biyolojik sinir hücrelerinin bir taklidi olan yapay sinir hücresinin 5 temel elemanı vardır. Şekil 2.2’ de görüldüğü gibi bir yapay sinir hücresi sırasıyla; girdiler, ağırlıklar, toplama fonksiyonu, aktivasyon fonksiyonu ve çıktılarından oluşur.

Şekil 2.2: Yapay Bir Sinir Ağı Yapısı



Kaynak: Elmas (2021, s. 35).

2.3.1. Girdi Değerleri

Girdi değerleri ($x_1, x_2, \dots, x_m$), yapay sinir hücresine hücrenin dışından veya diğer hücrelerden gelen verileri ifade etmektedir.


2.3.2. Ağırlıklar

Ağırlıklar, yapay sinir hücresine gelen girdi değerlerinin hücreye etkisini belirleyen katsayılar olup her girişin bir ağırlığı bulunmaktadır. Ağırlık değerinin büyük veya küçük olması, ilgili girişin ağırlığı küçük ise yapay sinir ağına zayıf bağlandığını ya da önemli olmadığını gösterirken ağırlık değeri büyükse yapay sinir ağına güçlü bağlandığını ya da önemli olduğunu ifade etmektedir (Elmas, 2021, s. 35).

2.3.3. Toplama Fonksiyonu

Yapay sinir hücresine gelen her bir girdi değerini kendisine ait ağırlık değeriyle çarpıp bulunan sonuçların toplamına eşik değerini de ekleyerek aktivasyon fonksiyonuna iletir (Elmas, 2021, s. 35).

Şekil 2.3: Basit Algılayıcı



Kaynak: Hamzaçebi (2021, s. 42).

Tablo 2.1’de kullanılabilecek toplama fonksiyonlarına yer verilmiştir.

Tablo 2.1: Bazı Toplama Fonksiyonları



Toplam $netgirdi = \sum_i w_i x_i$	Çarpım $netgirdi = \prod_i w_i x_i$
Maksimum $netgirdi = Maks(w_i x_i)$	Minimum $netgirdi = Min(w_i x_i)$
Signum $netgirdi = \sum_i Sgn(w_i x_i)$	

Kaynak: Hamzaçebi (2021, s. 40).

2.3.4. Aktivasyon Fonksiyonu

Toplama fonksiyonundan gelen veriyi işleyerek nihai olarak oluşacak çıktı değerini belirleyen işlemdir. Problemin çözümü için, araştırmayı yapan kişinin denemeleri sonucu ulaşılan en uygun fonksiyon belirlendiği için uygun fonksiyonun hangisi olduğunu gösteren sabit bir metot bulunmamaktadır (Yanık, 2019, ss. 56-57).

Tablo 2.2: Yaygın Kullanılan Aktivasyon Fonksiyonları

FONKSİYON ADI	MATEMATİKSEL GÖSTERİMİ	SİMGE
Doğrusal Fonksiyon (purelin)	$f(x) = x$	
Sigmoid Fonksiyonu (logsig)	$f(x) = \frac{1}{1 + e^{-x}}$	
Hiperbolik Tanjant Fonksiyonu (tansig)	$f(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}}$	
Eşik Değer Fonksiyonu (hardlim)	$\begin{aligned} f(x) &= 0 & x < 0 \\ f(x) &= 1 & x \geq 0 \end{aligned}$	

Kaynak: Hamzaçebi (2021, s. 41); Yavuz (2006, s. 22).

Tablo 2.2’de $(-\infty, +\infty)$ aralığında bulunan bir değeri; eşik değer fonksiyonu $\{0,1\}$ değerlerine dönüştürürken, sigmoid fonksiyonu $[0,1]$, tanjant sigmoid fonksiyonu ise $[-1,1]$ aralığındaki değerlere dönüştürmektedir. Doğrusal fonksiyonda ise gelen girdiler hücrenin çıktısı olarak belirlenmektedir (Yavuz, 2006, s. 22).

2.3.5. Hücrenin Çıktısı

Aktivasyon fonksiyonu sonucu ulaşılan değer yapay sinir hücresinin çıktı değeridir. Ulaşılan çıktı değeri başka sınırlara ya da dış dünyaya iletilir. Birçok girdi değeri olmasına rağmen yalnızca bir tane çıktı değeri vardır (Karacameydan, 2009, s. 46; Yanık, 2019, s. 58).

Tablo 2.3: Biyolojik Sinir Sistemi Elemanları ve Yapay Sinir Sisteminde Karşılıkları

Biyolojik Sinir Sistemi	Yapay Sinir Sistemi
Nöron	İşlemci Eleman
Dentrit	Toplama Fonksiyonu
Hücre Gövdesi	Transfer Fonksiyonu
Aksonlar	Yapay Nöron Çıkışı
Sinapslar	Ağırlıklar

Kaynak: Öztürk ve Şahin (2018, s. 28).

2.4. Yapay Sinir Ağlarının Avantajları ve Dezavantajları

Yapay sinir ağlarının sahip olduğu özellikler bazı avantajları da beraberinde getirmektedir. Bu avantajlar şu şekilde sıralanabilir:

2.4.1. Doğrusal Olmama

Yapay sinir ağlarının önemli bir özelliği olan doğrusal olmama özelliği, bu yöntemin gerçek yaşamdaki doğrusal olmayan yapılar için kullanılabilmesini sağlamaktadır. Ekonomi bilimi için düşünüldüğünde ekonomik verilerin doğrusal olmayan yapıda olmaları mümkündür. Ancak lineer yöntemlerle analiz edilmesi, doğrusal olmayan yapıya sahip veriler için doğru olmayan sonuçlara neden olabilir. Bu sebeple yapılan analiz için gerekli olan verilerin doğrusal olması veya doğrusal olmaması sonuçları etkilemektedir (Yurtoğlu, 2005, ss. 34-35).

2.4.2. Öğrenme

Yapay sinir ağları kendisine verilen örnekler ait bilgiler sayesinde kendi kendine öğrenmeyi gerçekleştirir ve bu bilgileri kullanarak sorunlar karşısında genelleme yapabilir. Ayrıca yapay sinir ağlarının verilen yeni örnekler ait verileri öğrenmesi ve yeni durumlara adaptasyonunda problem yaşamaması sonucunda oluşan sürekli öğrenme yeteneği, yapay sinir ağlarının sürekli olarak yeni olayları öğrenmesini sağlamaktadır. Bu özellikleri ile her bir problem için uzmanları tarafından farklı algoritma hazırlanması gereken geleneksel yöntemlere göre daha uygundur. (Bayır, 2006, ss. 8-9).

2.4.3. Genelleme Yapabilme

Öğrenme özelliğine bağlı olarak daha önceden karşılaştığı örnek veriler ile daha önce karşılaşmadığı olaylar için genelleme yapabilir. Böylece hatalı veya kayıp veriler için çözüm sunabilmektedir (Yurtoğlu, 2005, s. 36).

2.4.4. Uyarlanabilirlik

“Belirli bir problem için eğitilen YSA, problem değiştiğinde yeni probleme göre uyarlanabilir ve yeniden eğitilebilir.” (Hamzaçebi, 2021, s. 29).

2.4.5. Hata Toleransı ve Esneklik

Geleneksel işlemcilerde, her hareketi sırasıyla yapan sadece bir merkezi işlemci bulunmaktadır. Seri bilgi işlem yapan geleneksel bir sistemin bir biriminin tamamen bozulması veya hatalı çalışması tüm sistemi olumsuz etkileyerek bozulmasına ya da hatalı çalışmasına neden olacaktır. Yapay sinir ağları ise çok sayıda ve her biri problemin bir parçasıyla ilgilenen basit işlemci elemanlardan oluşmaktadır. Bununla birlikte bağlantı ağırlıklarının ayarlanabiliyor olması da yapay sinir ağlarının esnek bir yapıya sahip olduklarını göstermektedir. Sahip olduğu esnek yapı, ağın bir bölümünün zarar görmesi durumunda yalnızca modelde performansın düşmesine neden olmakta, modelin işlevinin tamamen yok olması durumu bulunmamaktadır. Böylece diğer geleneksel yöntemlere kıyasla hatayı tolere etme yeteneği çok yüksektir (Bayır, 2006, s. 9; Yurtoğlu, 2005, s. 35).

2.4.6. Paralel Çalışma

Bilgi işleme yöntemleri genellikle seri, sıralı işlemlerden oluşur. Seri işlemcilerde bir birimin yavaş çalışması durumu tüm sistemin yavaşlamasına neden olmaktadır. Yapay sinir ağlarında ise işlem elemanlarının her biri eş zamanlı çalışmaktadır. Bu nedenle sistem hızlı bir şekilde çıktı üretir. Paralel çalışan bir sistemde yavaş çalışan bir birimin sisteme etkisi çok az olup sistemde bir problem oluşturmamaktadır. Bu nedenle yapay sinir ağlarının daha hızlı ve güvenilir olduğu söylenebilir (Bayır, 2006, s. 8; Sevinçtekin, 2014, s. 9).

2.4.7. Hafıza

Yurtoğlu (2005, s. 36), yapay sinir ağlarında bulunan ağırlıklı bağlantıların bilgiyi saklayabildiğini ifade etmiştir.

2.4.8. Sınırsız Sayıda Değişken ve Parametre Kullanımı

Yapay sinir ağlarında sınırsız sayıda değişken ve parametre kullanımı mümkündür. Böylece başarılı bir tahmin yapabilme ve genel çözümlere ulaşma durumu söz konusudur (Sevinçtekin, 2014, s. 10; Yurtoğlu, 2005, s. 36).

2.4.9. Kendi İlişkisini Oluşturma

Yapay sinir ağları sabit bir denkleme sahip değildir. Verilere göre kendi ilişkilerini oluştururlar (Sevinçtekin, 2014, s. 10).

Yapay sinir ağları, tüm bu avantajlarına karşın bazı dezavantajlara da sahiptir. Bunlardan bazıları şöyle sıralanabilir:

- Yapay sinir ağlarının eğitimi ve test edilebilmesi için geniş veri setine ihtiyaç vardır. Ancak burada veri seti genişliği için belirli bir kriter olmayıp uygulamaya bağlıdır (Bayır, 2006, s. 11).
- Yapay sinir ağlarının sayısal olmayan verilerle çalışamaması ve bu sebeple analiz öncesi tüm verilerin sayısallaştırılması ihtiyacı da bir dezavantajdır (Yüksel, 2014, s. 60).
- “Dezavantaj sayılabilecek diğer bir nokta ise basit olarak görülebilecek modelleme yapılarına rağmen uygulamanın zor ve karmaşık olabilmesidir. Bazı durumlarda, bir yakınsama sağlamak bile imkânsız olabilmektedir fakat bu durum da uygulama alanına bağlıdır ve genellikle çok karmaşık problemlerde ortaya çıkmaktadır.” (Yurtoğlu, 2005, s. 37).
- Ağ eğitiminde, hata oranının kabul edilen değerler aralığında olması ağın eğitimi tamamladığı kabul edilmekle birlikte doğru bir çözüm olduğuna dair garantisi yoktur. Ayrıca ağın ne kadar eğitileceğinin belirli olmaması durumu bulunmaktadır. Bazen ağın ezberlemesi ya da takılması olasılığı vardır (Yıldız, 2006, s. 82).

2.5. Yapay Sinir Ağlarının Sınıflandırılması

Yapay sinir ağları; katman sayıları, bağlantı yapıları ve öğrenme şekilleri göz önünde bulundurularak sınıflandırılmaktadır.

2.5.1. Katman Sayısına Göre Yapay Sinir Ağları


Yapay sinir ağları katmanlarına göre ikiye ayrılır. Bunlar; tek katmanlı yapay sinir ağları ve çok katmanlı yapay sinir ağlarıdır.

2.5.1.1. Tek Katmanlı Yapay Sinir Ağları

Tek katmanlı yapay sinir ağlarında gizli katman bulunmamakta, yalnızca girdi ve çıktı katmanlarından oluşmaktadır. Bütün girdi üniteleri, çıktı ünitelerine bağlanmaktadır ve her bir bağlantı da bir ağırlığa sahiptir. Bu şekildeki ağlarda çıktı değerinin sıfır olmaması için eşik değeri (Φ) bulunmaktadır. Eşik değeri daima +1'dir. Tek katmanlı yapay sinir ağları daha çok

doğrusal problemler için kullanılmaktadır (Karacameydan, 2009, s. 54; Vural, 2007, s. 17). Doğrusal olmayan problemler için ise yetersiz olmuştur.

Şekil 2.4: Tek Katmanlı Yapay Sinir Ağları




Tek katmanlı yapay sinir ağlarının en önemlileri Basit Algılayıcı Modeli (Perceptron), Adaptif Doğrusal Eleman (Adaptive Linear Element- ADALINE) ve Çoklu Adaptif Doğrusal Eleman (Multiple Adaptive Linear Element- MADALINE)'dir (Yanık, 2019, s. 59).

2.5.1.2. Çok Katmanlı Yapay Sinir Ağları

Çok katmanlı yapay sinir ağları; girdi katmanı, çıktı katmanı ve bu katmanlar arasında yer alan bir ya da daha fazla gizli (ara) katmandan oluşur. Doğrusal olmayan problemlerin çözümünde başarılı olmuştur.

Şekil 2.5: Çok Katmanlı Bir Yapay Sinir Ağı



Kaynak: Elmas (2021, s. 52).

- **Girdi Katmanı:** Yapay sinir ağına dış dünyadan gelen verileri herhangi bir işlem yapmadan bir sonraki katmana göndermektedir. Girdi katmanındaki hücre sayısı kadar girdi verileri bulunmaktadır (Sail, 2021, s. 17; Sevinçtekin, 2014, s. 11).
- **Gizli Katman:** Kendisinden önceki girdi katmanından gelen verileri işleyerek çıktı katmanının kullanabilmesini sağlar. Herhangi bir yapay sinir ağında birden fazla gizli katman bulunabileceği gibi hiç gizli katman bulunmayabilir (Yanık, 2019, s. 59; Yavuz, 2006, s. 22). Gizli katmanı bulunmayan, sadece girdi ve çıktı katmanlarından oluşan ağ yapısı “Tek Katmanlı Yapay Sinir Ağı” olarak bilinmektedir. Gizli katmanın olmadığı modeller karışık yapıdaki veriler için yeterli olmazken, olması gereken sayıdan az sayıdaki gizli katmanı olan modeller de karışık fonksiyonlar için yetersiz kalmaktadır. Ancak gizli katmanın çok olması da sistemde kararsızlığa sebep olmaktadır (Sail, 2021, s. 17).

Gizli katman sayısı kadar gizli katmanda yer alacak nöron sayısının da belirlenmesi önemlidir. Gizli katmandaki nöron sayısı sinir ağındaki öğrenmenin daha iyi olmasını, aynı zamanda öğrenme esnasında hafızasında fazla bilgiyi tutmasını da sağlar (Yüksel, 2014, s. 62).

Hamzaçebi (2021, s. 118), gizli katmandaki nöron sayısının belirlenmesinde belirli bir yöntem olmadığını, bu nedenle deney tasarımı yapılabileceğini ifade etmiştir. Ayrıca “n” girdi nöronu “m” çıktı nöronu sayısını gösteren, bir gizli katmana sahip modellerdeki gizli nöron sayısının belirlenmesine dair şu önerilerin olduğunu belirtmiştir (Hamzaçebi, 2021, ss. 118-119):

- a) n (Tang ve Fishwick, 1993)
 - b) $2n+1$ (Lippmann, 1987)
 - c) $2n$ (Wong, 1991)
 - d) $\sqrt{n * m}$ (Masters, 1993)
 - e) $0,75*n$ (Baily ve Thompson, 1990)
- **Çıktı Katmanı:** Girdi katmanından sinir ağına gelen veriler için belirli çıktıları üreten katmandır (Yanık, 2019, s. 60).

“Doğrusal Vektör Parçalama Modeli (Linear Vector Quantization- LVQ)” ve “Çok Katmanlı Algılayıcı (Multilayer Perceptron) Modeli” bu tür yapay sinir ağlarına örnektir (Gür, 2009, s.

38). Ayrıca sigmoid fonksiyonu ve hiperbolik tanjant fonksiyonu, Çok Katmanlı Algılayıcılarda en sık kullanılan transfer fonksiyonlarıdır (Karacameydan, 2009, s. 56).

“Çok Katmanlı Algılayıcı Modeli’ne (ÇKA), “Hata Yayma Modeli” veya “Geriye Yayım Modeli” de denmektedir.” (Karacameydan, 2009, s. 56).

2.5.2. Bağlantı Yapısına Göre Yapay Sinir Ağları


Yapay sinir ağları bağlantı yapılarına göre ileri beslemeli ve geri beslemeli olarak iki grupta incelenir.

2.5.2.1. İleri Beslemeli Yapay Sinir Ağları

İleri beslemeli ağlarda modele giren bilgiler girdi katmanından çıktı katmanına doğru ileri ve geri dönüş yapmadan tek yönde ilerlemektedir. Aynı katmanda yer alan nöronlar arasında bağlantı bulunmazken her katmanda yer alan nöronlar arasında tüm nöronlara bağlantı vardır (Aydın, 2019, s. 19; Yanık, 2019, s. 60; Yavuz, 2006, s. 23). Yurtoğlu (2005, s. 28), çoğunlukla ileri beslemeli sinir ağlarının girdi veriye hızlıca karşılık ürettiklerini belirtmiştir. Yanık (2019, s. 61) ise bu mimariye sahip ağların genellikle sınıflandırma, örüntü oluşturma ve örüntü tanımadaki kullanıldığını ifade etmiştir.

MLP (Multilayer Perceptron) ve LVQ (Learning Vector Quantization) ileri beslemeli ağlara örnek olarak gösterilebilir (Aydın, 2019, s. 19).

Şekil 2.6: İleri Beslemeli Bir Yapay Sinir Ağı Mimarisi



Kaynak: Hamzaçebi (2021, s. 25).


2.5.2.2. Geri Beslemeli Yapay Sinir Ağları

Yapay sinir ağlarına gelen veri akışının yalnızca ileri yönlü değil geriye doğru olabildiği yapay sinir ağı türüdür (Asilkan & Irmak, 2009, s. 380). Gizli katmandan veya çıktı katmanından elde edilen verilerin önceki birimlere geri dönüş yapabildiği ağ yapısıdır. Bu türdeki sinir ağlarında en az bir geri besleme bulunmaktadır (Çanakcı, 2006, s. 24).

Vural (2007, s. 25), geri beslemenin aynı katmanda yer alan hücreler arasında ya da farklı katmanlardaki hücreler arasında olabileceğini, bu durumun geri beslemeli yapay sinir ağlarının doğrusal olmayan dinamik bir davranışa sahip olduğunu gösterdiğini ifade etmiştir. Geri beslemeli yapay sinir ağlarıyla ilgili, Yurtoğlu (2005, s. 28) “Geri beslemeli ağlarda (Recurrent Networks) ise bağlantılar döngü içerirler ve hatta her seferinde yeni veri kullanabilmektedirler. Bu ağlar, döngü sebebiyle girdinin karşılığını yavaş bir şekilde oluştururlar. Bu yüzden, bu tür ağların eğitime süreci daha uzun olmaktadır.” şeklinde açıklamış ve aynı zamanda hem ileri besleme hem geri yayılma olarak tanımlaması yapılabilecek ağ yapılarının da bulunduğunu belirtmiştir.

Geri beslemeli yapay sinir ağları çoğunlukla danışmansız öğrenme kurallarının uygulandığı ağ yapılarında kullanılır. Hopfield ağının mimarisi de buna örnektir. Bu tür ağ yapısında sinir ağının ulaştığı çıktısıyla, beklenen çıktısı arasındaki fark hata olarak isimlendirilirken amaç hatanın en aza indirilmesidir. Hopfield ve Kohonen ağları buna örnek olarak gösterilebilir (Çanakcı, 2006, ss. 24-25).

Şekil 2.7: Geri Beslemeli Ağ Yapısı



Kaynak: Hamzaçebi (2021, s. 31).

2.5.3. Öğrenme Şekline Göre Yapay Sinir Ağları


Öğrenme yeteneğindeki gelişmişlik yapay sinir ağlarını diğer tahmin metotlarından farklılaştıran özelliktir. Tıpkı insanların geçmişteki yaşadıkları tecrübeler sonucu elde ettikleri bilgilerle, karşılaştıkları sorunlara karşı gösterdikleri tutum gibi yapay sinir ağlarının da amacı önceki deneyimledikleri örneklerden hareketle ilgili konu hakkında bilgi sahibi olarak sonradan karşılaşılabileceği yeni örneklerin sonuçlarına en yakın sonucu bulabilmektir (Korkut, 2019, s. 23). Öğrenme şekline göre üç çeşit yapay sinir ağları bulunmaktadır.

2.5.3.1. Danışmanlı Öğrenme

Danışmanlı öğrenme yönteminde yapay sinir ağının eğitiminde bir danışman- öğretmen öğrenilmesi beklenen olayın hem girdi verilerini hem de çıktı verilerini sinir ağına sunmaktadır. Bu bilgiler içerisinde girdi verilerine göre sistem kendi ulaştığı çıktı verilerini oluşturur. Böylece sisteme önceden örnek olarak sunulan çıktı verileri ile ağın ürettiği çıktı verileri kıyaslanarak aradaki fark yani hata oranı belirlenmektedir. Belirlenen hata oranını minimize etmek amacıyla sinir ağındaki ağırlık değerleri değiştirilir. Bu durum hata oranı en makul düzeye geldiğinde ağın eğitimi tamamlanmış olur. Danışmanlı öğrenme yönteminde Ortalama Mutlak Hata ve Hata Kareleri Ortalamasının Karekökü ölçütleri kullanılmaktadır. Delta Kuralı, danışmanlı öğrenme yöntemi algoritmalarındandır (Yanık, 2019, s. 62).

Bayır (2006, s. 33), Tek Katmanlı ve Çok Katmanlı Algılayıcıların danışmanlı öğrenmeye örnek olduğunu ifade etmiştir.

Şekil 2.8: Danışmanlı- Öğretmenli Öğrenme




Kaynak: Haykin (2009, s. 35).

2.5.3.2. Danışmansız Öğrenme

Danışmansız öğrenmede sinir ağının eğitimine yardımcı öğretmen- danışman bulunmamaktadır. Sisteme örnek çıktı verileri sunulmaz. Yalnızca girdi verileri sunularak parametrelerin arasındaki bağlantının sinir ağı tarafından kendi kendine kurulması beklenir. Böylece bu bilgilere göre ağırlık değerini sistem kendi belirlemektedir (Korkut, 2019, s. 24; Yanık, 2019, s. 62).

Şekil 2.9: Danışmansız- Öğretmensiz Öğrenme



Kaynak: Haykin (2009, s. 37).


Karacameydan (2009, s. 53), bu öğrenme yönteminin çoğunlukla sınıflandırma problemlerinde kullanıldığını belirterek, ART (Adaptif Rezonans Teorisi) ağları ve Hebb, Hopfield, Kohonen öğrenme kurallarının danışmansız öğrenme yöntemine örnek olduğunu ifade etmiştir. Ayrıca, Bayır (2006, s. 33) SOM (Self Organizing Map) ağının da danışmansız öğrenmeye örnek olduğunu belirtmiştir.

2.5.3.3. Destekleyici Öğrenme

Hamzaçebi (2021, s. 33), destekleyici öğrenme yönteminde de danışmanlı öğrenmede olduğu gibi bir öğretmenin yardımcı olduğunu fakat sisteme hedef çıktıların sunulmadığını ve böylece bir girdi verisi için, sistemin ulaşılan çıktı verisinin doğru ya da yanlış olduğunu bildiren sinyal ürettiğini buna göre de ağırlık değerinin düzenlendiğini ifade etmiştir. LVQ (Learning Vector Quantization), Boltzman Makinesi ve eğitimde Genetik Algoritma kullanan ağlar destekleyici (takviyeli) öğrenme yöntemine örnektir (Bayır, 2006, s. 33).

Radyal tabanlı ağlar (RBN) ve olasılık tabanlı ağlar (PBNN), kısmen öğretmenli kısmen öğretmensiz öğrenme yapan (karma stratejili öğrenme yapan) ağlara örnek verilebilir (Yavuz, 2006, s. 25).

Şekil 2.10: Destekleyici- Takviyeli Öğrenme



Kaynak: Haykin (2009, s. 36).

2.6. Öğrenme Kuralları

Hebb Kuralı, en iyi bilinen ve en eski kural olmakla birlikte yapay sinir ağlarının öğrenmesinde birçok kural kullanılmaktadır. Ancak bu kuralların çoğu Hebb Kuralı'nın çeşitlemeleridir (Yavuz, 2006, s. 27). Öğrenme kurallarından bazıları şunlardır:

2.6.1. Hebb Kuralı

Donald Hebb'in 1949'da yazdığı kitapta tanımladığı ilk ve temel öğrenme kuralıdır. Hebb Kuralı'na göre birbirine bağlı olan nöronların ikisi de aktif yani matematiksel olarak aynı işaretliyse, nöronlar arasındaki ağırlık artırılmalıdır (Elmas, 2021, s. 38).

2.6.2. Hopfield Kuralı

Hebb Kuralı'na benzer ancak nöronlar arasındaki bağlantıların kuvvetlendirilmesi veya zayıflatılması için miktar belirlenir. Girdi verileri sonucu ulaşılan çıktı verilerinin tutarlı olması yani her ikisinin de aktif veya her ikisinin de pasif olduğu durumlarda ağırlık değerinin öğrenme katsayısı kadar artırıldığı ya da azaltıldığı öğrenme kuralıdır. Genellikle 0-1 arasında olan öğrenme katsayısını kullanıcı belirlemektedir (Yanık, 2019, s. 65).

2.6.3. Delta Kuralı

Delta Kuralı, Windrow- Hoff Öğrenme Kuralı veya En Küçük Kareler Öğrenme Kuralı olarak da bilinmektedir (Hamzaçebi, 2005, s. 62). 1960 yılında Windrow ve Hoff tarafından geliştirilmiştir ve en çok kullanılan kurallardandır. Bu kuralda sinir ağının eğitimi aşamasında beklenen ve gerçekleşen çıktı verisi arasındaki sapmayı (farkı) azaltabilmek için bağlantı

ağırlıklarının sürekli değiştirilmesi gerekir. Bağlantı ağırlıklarının sürekli değişmesi, beklenen çıktı ve gerçekleşen çıktı arasındaki farkın yani hatanın azaltılmasını sağlamaktadır (Elmas, 2021, ss. 102-103).

2.6.4.Kohonen Kuralı

Teuvo Kohonen tarafından geliştirilmiş olan bu kurala göre sinirler, ağırlıklarını değiştirmek için birbirleriyle yarış halindedir. En uygun çıktıya ulaşan sinir hücresi ise kazandır ve yakınındaki diğer sinirlerin ağırlıklarını değiştirir (Yüksel, 2014, s. 75).

2.6.5. Eğimli İniş Kuralı

Hamzaçebi (2005, s. 62) bu kuralı; “Delta kuralının benzeridir. Ağırlıkların düzenlenmesi işlemi, bir işlem birimi için arzu edilen çıktı ile gerçek çıktı arasındaki hatanın birinci türevine (gradient) göre orantılı bir şekilde gerçekleştirilir. Amaç, hata fonksiyonunu azaltarak, yerel minimumdan kurtulmak ve genel minimumu yakalamaktır.” şeklinde açıklamaktadır.

2.7. Yapay Sinir Ağlarının Uygulama Alanları

Yapılan araştırmalar incelendiğinde yapay sinir ağları yönteminin; mühendislik, ekonomi, tıp gibi birçok alanda gerçek yaşamda karşılaşılan pek çok problemler için kullanılan bir yöntem olduğu görülmektedir.

Hamzaçebi (2021, ss. 34-35) yapay sinir ağlarının uygulama alanlarını aşağıdaki gibi sıralamıştır:

- **Sınıflandırma:** Bir nesnenin hangi sınıfa ait olduğunun belirlenmesidir. Burada birden çok sınıf arasından seçim yapılmaktadır. El yazısının ayırt edilmesi ya da bankaların kredi vereceği müşterileri için riskli veya risksiz sınıflandırması yapması gibi örnekler verilebilir.
- **Kümeleme:** Benzerlikleri olan nesnelerle bir grup oluşturulmasıdır. Sınıfların tanımının önceden bilinmesi kümelemeyi sınıflandırmadan ayırmaktadır.
- **Fonksiyon Yaklaşımı:** Girdi verileri ve çıktı verileri bilinmesine rağmen aralarındaki bağlantının bilinemediği durumlarda, aynı girdi verisi için yaklaşık aynı çıktı verisine ulaşmayı sağlayan işlevin tanımlanmasıdır.
- **Örüntü Tanıma:** Yapay sinir ağının önceden tanıdığı örüntülerle eksik örüntüler karşılaştırıldığında bozuk veya eksik örüntünün doğrusunun bulunmasıdır. Yüz tanıma işlemi yardımıyla kimlik doğrulaması yapılması amacıyla kullanılabilir.

- **Optimizasyon:** Bazı kısıtlar dâhilinde belli bir amacın optimize edilmesini sağlamak için kullanılabilir.
- **Tahmin:** Firmaların karar vermelerinde önemli olan satış tahmini, fiyat tahmini, borsa, finans gibi alanlarda yapay sinir ağları kullanılmaktadır. Hisse senedi fiyat tahminleri gibi birçok değişkene bağlı, doğrusal olmayan özellikteki karmaşık yapıya sahip tahminlerde geleneksel yöntemler bazı sınırlamalar getirirken yapay sinir ağları yöntemi doğru uygulandığında rahatlıkla kullanılabilir (Yanık, 2019, s. 48).

Robot sistemlerinin kontrolü, uçaklarda otomatik pilot sistemi otomasyonu, uçakların ve elektrik makinelerinin arıza analizi, kanserli hücre analizi, protez tasarımı, hastanelerde giderlerin optimizasyonu, üretim sistemlerinin optimizasyonu, kalite kontrol ve analizi gibi birçok alanda yapay sinir ağları kullanılmaktadır (Bahadır, 2008, s. 40).

2.8. Hisse Senetlerinin Fiyat Tahmini İçin Yapay Sinir Ağları ile Yapılan Çalışmalar

Yapay Sinir Ağlarının kümeleme, sınıflandırma, örüntü tanıma, tahmin gibi birçok uygulama alanı olduğu bilinmektedir. Bunlardan tahmin yapabilme yeteneği araştırmalarda mühendislik, işletme, finans, tıp gibi birçok bilim dalında kullanılmıştır. Yapay sinir ağları yöntemi işletme ve finans alanında gelecekteki fiyat, mali başarısızlık, döviz kuru ve talep tahminleri gibi birçok konuda araştırmalarda kullanılan bir analiz yöntemidir.

Yüksel ve Akkoç (2016), YSA yöntemiyle altın fiyatlarını tahmin etmeye çalışmışlardır. Brent petrol, gümüş, 13 hafta vadeli ABD Hazine Bonosu faiz oranı, ABD TÜFE, EURO/ABD Dolar paritesi, EURO Next100 Endeksi, ABD Dow Jones Endeksi verileri bağımsız değişkenler; altın ons fiyatı ise bağımlı değişken olarak YSA modeline sunulmuştur. 2 ve 16 arasındaki nöron sayısı ile tek tek hesaplamalar yapılmış ve R^2 , MAE, MAPE ve RMSE değerleri belirlenmiş buna göre de 16 nöronla hazırlanan modelin en iyi sonuca sahip olduğu belirtilmiştir. Kosinüs Genlik Metodu altın fiyatını etkileyen etmenleri bulmak amacıyla duyarlılık analizinde kullanılmış ve altın fiyatını en çok gümüş; sonrasında ise brent petrolün etkilediği açıklanmıştır.

Yavuz vd. (2015), BİST Sınai Endeksi'ndeki 140 hisse senedi ile aktif büyüklük, piyasa değeri, özsermaye ve işlem hacmine göre portföyler oluşturmuşlardır. Oluşturulan portföylerin risk-getiri hesaplaması yapılmıştır. Analiz sonucu özsermayeye göre oluşturulmuş portföylerin getiri-risk açısından en iyi sonuca ulaştığını ve yapay sinir ağı analizinin getiri tahmininde %1'den az hata oranı gösterirken risk tahmininde %0.5'den az hata oranı gösterdiğini belirtmişlerdir.

2012’de Akel ve Karacameydan tarafından yatırım fonu net varlık deęerini YSA modeliyle tahmin etmeye ynelik bir arařtırma yapılmıřtır. 19 adet A tipi ve 19 adet B tipi olmak zere 38 adet yatırım fonu net varlık deęeri belirlenmiřtir. Aktif tahvil faiz oranı, ABD Doları/TL, Toptan Eřya Fiyat Endeksi (TEFE), İMKB 100, Para arzı ve Sanayi retim Endeksi gibi makroekonomik gstergeler baęımsız deęiřkenlerdir. Oluřturulan YSA modellerinin iyi bir tahmin performansına sahip olduęu belirtilirken gerek rneklem dıřı gerekse rneklem ii dnemlerdeki finansal krizlerin tahmininde regresyon yntemine gre bařarılı olduęu ifade edilmiřtir. YSA yntemine gre kıyaslandığında regresyon ynteminin byk sapmalar gstermiř olduęu aıklanmıřtır. Ayrıca finansal deęiřkenler iin YSA analizinin etkili olduęu řeklinde genelleme yapılabileceęi ifade edilmiřtir.

2009’da Asilkan ve Irmak, ikinci el otomobillerin gelecekteki fiyatlarını Yapay Sinir Aęları ve Zaman Serisi Analizi yntemleri ile tahmin etmeye alıřmıřlardır. alıřmada modelin girdi deęiřkeni olarak 40 adet web sitesindeki Volkswagen, BMW ve Mercedes marka araba modellerinin 12 aylık ve 20.000 km’deki ilanlarının Ocak 2005- Aralık 2007 dnemlerindeki 3 yıllık gnlk fiyat verilerinin aylık ortalaması ile zaman serileri oluřturulduęu belirtilmiřtir. Zaman serisi analizinde R ve SPSS yazılımları kullanılırken, geri yayılımlı ęrenme algoritması kullanılan YSA modelinde verilerin %90’ı eęitim %10’u test amalı kullanılmıřtır. YSA modeline ait dięer bilgiler ise 1 girdi nronu, 1 gizli katman, 2 gizli nron, 1 ıktı nronu, aktivasyon fonksiyonunun Hiperbolik Tanjant olarak belirlenmiř olmasıdır. Arařtırma sonucunda her iki yntemde de Ortalama Mutlak Hata (MAE), Ortalama Mutlak Yzde Hata (MAPE) ve Ortalama Hata Kareleri Kk (RMSE) hata fonksiyonlarına gre karřılařtırıldığında YSA’nın Zaman Serisi Analizine gre daha gvenilir sonular elde ettięi ifade edilmiřtir.

Altan (2008), dviz kuru tahminlerinde aylık veriler ile ileri beslemeli YSA ve Vektr Otoregresif (VAR) Modeli kullanarak rneklem ii ve rneklem dıřı dnemlerin hata oranlarına bakıldığında YSA’nın bařarisının grldęn ayrıca VAR ve YSA ngrleri birleřtirildięinde dviz kuru tahmin bařarisını arttırdıęından sz etmektedir.

Kim vd. (2004), olası ekonomik krizler iin uyarı verebilecek Erken Uyarı Sisteminin eęitilmesi konusunda sınıflandırma yapmak amacıyla karar aęacı, destek vektr makinesi, lojistik ayırma, bulanık sinir aęı ve YSA analizlerini kullanmıřlardır. Arařtırmada Kore Hisse Senedi Fiyat Endeksi (KOSPI) verileri kullanılarak gerekleřtirilen arařtırma sonucunda istikrarsız, istikrarlı ve kriz dnemi olmak zere sınıflandırmada uygun olan modellerin karar aęacı ve YSA olduęu belirtilmiřtir.

Hisse senetlerinin fiyat tahminleri ile ilgili literatürde birçok araştırmalar bulunmaktadır. Bu çalışmalardan bazıları aşağıda açıklanmıştır.

Sarı ve Saka Iğın (2022), araştırmalarında “BRICS borsa endeksleriyle BİST 100 endeksi tahmin edilebilir mi?” sorusuna YSA yöntemiyle yanıt aramışlardır. 2008 Şubat - 2019 Aralık arasındaki dönemlere ait aylık bazdaki 143 gözlem değeri kullanılmıştır. BİST 100 endeksi aylık kapanış değeri bağımlı değişken, BRICS (Brezilya, Rusya, Hindistan, Çin ve Güney Afrika) ülkelerinin borsa aylık kapanış değerleri ise bağımsız değişkenlerdir. Belirlenen değişkenlere ait 20 model test edilmiştir. Çalışmada SPSS 22, Statistica paket programından yararlanıldığı belirtilmiştir. Modeldeki verilerin %70’i eğitim %30’u test amaçlı kullanılmıştır. Çalışmada verilerin daha verimli olması amacıyla Max Kuralı ile normalleştirme, ağırlık eğitimi ise bulanıklaştırma yapıldığı belirtilmiştir. Modelin başarı değerleri Verimlilik Katsayısına (VK) göre değerlendirilmiş 0,70 ve üzeri yüksek tahmin başarısına sahip modeller olarak kabul edilmiştir. Çalışmadaki 20 modelin ilk dokuzunda VK değeri 0,70’in üzerinde değerlerdir. Sonuç olarak BİST 100 Endeksini tahmin etmede en başarılı endeksler sırasıyla Hindistan, Güney Afrika ve Rusya olurken Brezilya ve Çin ise başarısız bulunmuştur. Yazarlar, tüm bu veriler sonucunda portföy çeşitlendirmesi yapan bir yatırımcının Çin ve Brezilya borsalarına yönelmelerinin kârlılıklarını artırabileceğini belirtmişlerdir.

Özcan Akdağ vd. (2022), BİST Ulaştırma Endeksi tahminini aylık ve günlük veriler ile YSA NARX modeli kullanarak yapmışlardır. Araştırma sonucunu değerlendirebilmek için Ortalama Mutlak Sapma (MAD), Ortalama Kare Hata (MSE), Ortalama Kare Hatanın Karekökü (RMSE), Ortalama Mutlak Yüzde Hata (MAPE) değerlerine bakılmış ve MAPE değerinin %10’un altında yer almasının “çok iyi” modellenmiş olduğu belirtilmiştir. Araştırma sonucunda MAPE değerleri aylık veriler için %2,6325; günlük veriler için ise %1,8452 olarak bulunmuştur. Sonuç olarak YSA NARX modeli ile yapılan çalışmada aylık ve günlük verilerle elde edilen sonuçlar karşılaştırıldığında günlük verilerin tahmin açısından daha başarılı olduğunun gözlemlendiği belirtilmiştir. Ayrıca ulaştırma sektöründe negatif etkisi bulunan Covid 19 salgınının hazırlanan tahmin modellerinde etkisinin bulunmadığı; tahmin yeteneğini bozmadığı ifade edilmiştir.

Demirel ve Hazar (2021), araştırmada 2014-2019 yılları arasındaki DOW30, DAX, FTSE100, EURO STOXX50 ve BİST 100 endekslerinin günlük verilerini almışlardır. En yüksek, en düşük ve açılış değerleri ile günlük değişim verilerinin kullanılmış olduğu ifade edilmiştir. Çalışmada ikili sınıflandırma yöntemi gerçekleştirilerek endekslerin günlük hareket yönü

artmışsa 1, azalmışsa 0 olarak gösterilmiştir. Değişimin olmadığı verilerin temizlendiği ifade edilmiştir. Son durumda 5275 adet veri bulunmakta olup bu veri kümesi YSA'nın eğitimi için kullanılmıştır. BİST 100 hareket yönünü tahmin etmek için her biri 4 farklı YSA mimarisi tasarlanmış olduğu belirtilerek her bir model için 4 girdi değeri, 1 çıktı değeri bulunurken gizli katmandaki nöron sayısında değişiklikler yapıldığı ifade edilmiştir. Tasarlanan 4 modelin karmaşıklık matrisi performansı incelenmiştir. Analiz sonucunda 4 modelin eğitimden sonraki bilgileri tahmin başarısının, her biri için %50'nin üzerinde olduğu açıklanmıştır. En başarılı modelin %59,57 ile 1 gizli katmanı ve gizli katmanda 10 nöron bulunan model olduğu ifade edilmiştir.

Koç Ustalı vd. (2021) BİST 30 Endeksi'ndeki 22 şirketin 31.01.2010- 31.12.2019 tarihleri arasındaki üç aylık finansal tabloları yardımıyla asit-test oranı, cari oran, nakit oran, özsermaye devir hızı, özsermaye kârlılığı, net kâr marjı ve mali yapı oranlarını hesaplayıp analize girdi değerleri olarak eklemişlerdir. Çıktı verisi ise hisse senetlerinin aylık kapanış fiyatlarının 3 aylık ortalaması hesaplanarak elde edildiği belirtilmiştir. Araştırmadaki verilerin %70'i eğitim verisi olarak kullanılmış, analizin test verisinin başarılı olmasının yanında modelin eğitim ve test verilerinde gösterdiği performans değerlerinin birbirine yakın olması gerektiği belirtilmiştir. Yapay sinir ağları (YSA), Aşırı Gradyan Artırma (XGBoost) algoritması ve Rastgele Orman (RO) algoritması ile oluşturulan modeller Python dili ile kodlanmış olup modellerin performans göstergesinin R^2 olarak belirlendiği ifade edilmiştir. Modellerden YSA'nın gizli katman sayısı 1 ve 2, gizli katmandaki nöron sayıları 2, 4, 6, 8, 10; aktivasyon fonksiyonları Lojistik ve Relu fonksiyonlarına göre oluşturulmuş modeller içinden en iyi değere gizli katman sayısı 2, gizli katmandaki nöron sayıları 6-10, Relu aktivasyon fonksiyonuna göre oluşturulan modelde ulaşıldığı belirtilmiştir. Analiz sonucunda test verileri değerlerinin YSA %70,8 XGBoost %75,8 ve RO %70,2 oranında doğru tahmine ulaştığı gözlemlenmiştir.

Karakul (2020), BİST 100 Endeksi'ni etkileyen değişkenler arasındaki ilişkilerin modellenmesi amacıyla İleri Beslemeli Geriye Yayılımlı Çok Katmanlı Algılayıcı modeli ile yapay sinir ağı modeli oluşturmuştur. 4.01.2010-7.01.2020 tarihleri arasındaki 2511 işgününe ait veriler kullanılmış, verilerin %90'ı eğitim %10'u test verileri olarak belirlenmiştir. Araştırmada BİST 100 Endeksi verileri bağımlı değişken, gecelik faiz oranı ve dolar kuru ise bağımsız değişkenlerdir. Çalışmada MATLAB 2020a programı kullanıldığı belirtilerek ağın eğitim fonksiyonu Levenberg-Marquardt, Gradient Descent with Adaptive Learning Rate ve One Step Secant; aktivasyon fonksiyonları Momentum ile Azalan Gradyan (Gradient Descent

with Momentum- GDM), Azalan Gradyan (Gradient Descent- GD); transfer fonksiyonları Hiperbolik Tanjant Sigmoid (Tansig), Purelin (Lineer), Logaritmik Sigmoid (Logsig) arasında değiştirilerek 18 deney yapılmış ve en iyi sonuç veren modelin R değerine göre Levenberg-Marquardt, Momentum ile Azalan Gradyan ve Tansig fonksiyonlarından oluşan model olduğu belirtilmiştir. Daha sonra bu modele farklı mimarilere sahip 8 YSA modeli oluşturulmuştur. Buna göre 2 gizli katmanlı ve nöron sayıları 2-10-10-1 olan eğitim fonksiyonu LM, aktivasyon fonksiyonu GDM, transfer fonksiyonu tansig olan YSA modelinin tahmin performansının yüksek olduğu açıklanmıştır.

Çınaroğlu ve Avcı (2020), 2015-2018 dönemlerindeki günlük verileri kullanarak Türk Hava Yolları'nın hisse senedi fiyatlarını YSA modeli ile tahmin etmeye çalışmışlardır. Araştırmada Çok Katmanlı YSA modellerinde kullanılan Levenberg Marquart (LM) ve Bayesian Regulation (BR) öğrenme algoritmaları karşılaştırılmış sonuç olarak BR öğrenme algoritmasının daha başarılı olduğu belirlenmiştir. Oluşturulan YSA modeli belirlenen 10 günlük test verisi için uygulandığında modelin tahmin performansının yüksek olduğu ifade edilmiştir.

Sarıkaya (2019), BIST Ulusal 100 endeksinin 2005-2012 dönemlerindeki aylık kapanış fiyatlarını kullanarak 2013'deki aylık kapanış fiyatlarını tahmin etmiştir. Bunun için analizde Kübik Regresyon Modelini ve Yapay Sinir Ağları yöntemlerini kullanmıştır. Analiz sonucunda Ocak-Mayıs dönemlerindeki tahminler incelendiğinde yapay sinir ağı ile oluşturulan model Kübik Regresyona göre gerçeğe daha yakın sonuçlar vermiştir. Ancak siyasi ve politik sebepler gibi beklenmeyen ve modele eklenemeyen faktörler nedeniyle her iki modelde de gerçekte Haziran ayı ve sonrasında düşüş ve dalgalanmalar olurken, iki analizin tahmin sonucunda da düşüş gözlemlenmediği belirtilmiştir.

Yiğiter vd. 2017'de yaptıkları bir araştırmada hisse senedi fiyatlarını Bulanık Mantık, Yapay Sinir Ağları ve Çoklu Doğrusal Regresyon yöntemleriyle tahmin etmeye çalışmışlardır. Zaman serisi verileri ilk haliyle regresyon analizi yapıldığında sonucun yeterli olmadığı görülerek bazı işlemler sonucunda normal dağılımlı yeni bir zaman serisine ulaşılmış ve bu verilere göre üç yöntem uygulanmıştır. Sonuç olarak YSA modellerinden Scaled Conjugate Gradient eğitim fonksiyonu ve 3 gizli nörona sahip modelin 0,823 verimlilik katsayısı ile diğer YSA modellerinden en iyi sonucu verdiği ifade edilmiştir. Çoklu Doğrusal Regresyon modelinin 0,84; Bulanık Mantık yönteminin ise 0,851 verimlilik katsayısına sahip olduğu belirtilmiştir. Araştırmacılar regresyon analizine göre YSA ve Bulanık Mantık yöntemlerinin daha gerçekçi sonuçlar verdiğini ifade etmişlerdir.

Özçalıcı (2016), yaptığı araştırmada BIST30 endeksinde yer alan hisse senetlerinin 1 gün, 2 gün ve 20 gün sonraki fiyat tahmini için yapay sinir ağları yöntemini kullanmıştır. Çalışma sonucunda 1 gün sonraki fiyat eğilimine göre 20 gün sonraki fiyat eğiliminin tahmin oranının incelenen hisse senetlerinin birçoğunda daha yüksek olduğu ortaya çıkmıştır. Yazar, Tofaş Türk Otomobil Fabrikası A.Ş. (TOASO) hisse senedinin fiyatının 20 gün öncesinden %72,88 oranında doğru tahmin edildiğini ve bu sonucun literatürdeki diğer çalışmaların çoğundan yüksek olduğunu ifade etmiştir.

2015'te yapılan bir araştırmada Çalışkan ve Deniz BIST30 endeksindeki 27 hisse senedi fiyat hareketlerini tahmin etmişlerdir. Sonuçta tahminlerde elde edilen ortalama mutlak hata 21 kuruş, ortalama mutlak yüzde hata %1,80 olarak belirlenmiştir. Fiyatların artma- azalma yönündeki tahmin başarısı %58'dir. Yazarlar, endüstri ve firmaya mahsus değişkenlerin modelin girdi değişkenlerine eklendiğinde daha başarılı sonuçlar elde edilebileceğini ifade etmişlerdir.

Akcan ve Kartal (2011), İMKB'de bulunan 7 sigorta şirketinin hisse senedi fiyatlarını YSA modeli ile 15 gün, 1 ay, 1,5 ay ve 2 aylık dönemler için tahmin etmişlerdir. Yazarlar özellikle 1 aya kadar yapılan tahminlerin daha başarılı olduğunu ancak 2 aya kadar olan tahminlerin de hepsinde başarılı sonuçlar alındığını belirtmişlerdir.

“Kriz Dönemlerinde Yapay Sinir Ağları ile Finansal Öngörüle Bulunma: İMKB 100 Endeksi Örneği” isimli çalışmada Akel ve Bayramoğlu (2008), Şubat 2001'deki finansal krizde İMKB 100 Endeksi'ni bazı makroekonomik verileri kullanarak tahmin etmek adına YSA modeli geliştirmişlerdir. Araştırmada 2 yıllık bir dönem ve 521 iş gününe ait verilerin 1-502 aralığındaki kısmı eğitim, doğrulama ve test amaçlı; 503-521 aralığındaki kısmı ise öngörü amaçlı olmak üzere Çok Katmanlı ve Geri Besleme Algoritmasına sahip YSA analizi yapılmıştır. Modelin; eğitim, doğrulama ve test aşamaları sonuçları için Ortalama Mutlak Yüzde Hata oranı belirlenmiş ve bu sonuçlar birbirine yakın olduğu için tahmin aşamasına geçildiği ifade edilmiştir. Analiz sonucunda 21.02.2001 krizinden sonraki tahminlerin önceki dönemdeki kadar güçlü olmadığı ancak kriz öncesi ve sonrası dönem için fiyat hareketlerinin önceki güne göre artış ya da azalış göstereceği konusundaki tahminlerin %73,68 doğrulukla öngörülebildiği belirtilmiştir.

Toraman (2008), demir çelik sektöründe yer alan iki şirketin hisse senedi fiyatlarını YSA modeli ile tahmin etmeye çalışmıştır. Çalışmada modelin fiyat tahmini yapılan iki şirket için de başarılı sonuçlar verdiği belirtilmiştir. YSA oluşturulma aşamasında eğitim- doğrulama- test aşaması olarak üç gruba ayrılmasının volatilitesi yüksek dönemlerin modellenmesinde

başarılı olunmasını sağlamasına karşın aşırı volatilité dönemlerinde diğér tahmin modellerinde olduđu gibi çok da başarılı olamadıđı ifade edilmiştir.

Tektaş ve Karataş (2004), yaptıkları çalışmada 2002-2003 yıllarını baz alarak 3'ü çimento ve 4'ü gıda sektöründe yer alan 7 adet şirketin hisse senetlerinin fiyat tahmini için doğrusal regresyon ve YSA modelini kıyaslamışlardır. Öncelikle günlük ve haftalık verilere göre analiz yapılmış ve günlük verilerin tahmin için daha başarılı sonuçlar verdiđi ifade edilmiştir. Buna bađlı olarak da günlük veriler ile doğrusal regresyon ve YSA modeli korelasyon katsayısı kıyaslanmış ve YSA modeline ait korelasyon katsayısının daha anlamlı olduđu ve hisse senedi fiyat tahminlemesinde YSA modelinin alternatif olabileceđi sonucuna ulaşılmıştır.

Chen vd. (2003), Olasılıksal Sinir Ađı modelini kullanarak Tayvan Menkul Kıymetler Borsası piyasa endeksi getirisini tahmin etme ve yönünü modellemeye çalışmışlardır. Ocak 1982- Ağustos 1992' ye kadar olan süreci kapsamakta olup Ocak 1982- Ağustos 1987 ve Eylül 1987- Ağustos 1992 olmak üzere iki döneme ayrılmaktadır. Ocak 1982- Ağustos 1987 aralığındaki dönem örneklem içi tahmin dönemi olarak model seçimi ve doğrulama amacıyla, ikinci grup olan Eylül 1987- Ağustos 1992 dönemi ise örneklem dışı değerlendirme dönemi olup modellerin tahminlerini karşılaştırmak amacıyla kullanıldıđı belirtilmiştir. Kalman Filtresi ile Genelleştirilmiş Momentler Yöntemi (GMM), Rassal Yürüyüş ve YSA modelleri kullanılarak bu üç yöntemin performansı karşılaştırılmıştır. Olasılıksal Sinir Ađı'nın diğér yöntemlere göre getiri yönünü tahminde daha başarılı olduđu açıklanmıştır.

2003'de yaptıkları bir araştırmada Özalp ve Anagün, İMKB'de işlem gören Koç Holding'in hisse senetleri fiyatlarını Çoklu regresyon analizi ve Yapay Sinir Ađları ile tahmin etmeye çalışmışlardır. Yapay Sinir Ađları Analizinde ise modeli etkileyen faktörlerin rassal (rastgele) seçildiđi ve Taguchi Yöntemine göre belirlendiđi iki analiz yapılmıştır. Araştırma sonucunda tahmin hatalarının Taguchi Yöntemine göre yapılan YSA analizinde %15.13, modeli etkileyen faktörlerin rassal (rastgele) seçildiđi YSA analizinde %34.42 ve Çoklu Regresyon analizinde %32.30 olarak belirlendiđi ifade edilmiştir.

Kanas ve Yannopoulos (2001), Birleşik Krallık için Financial Times All Share (FT) ve ABD için Dow Jones Industrial Average (DJ) hisse senedi endekslerindeki ticaret hacmi, hisse senedi getirileri ve temettüler konusunda aylık verileri kullanmışlardır. YSA ve doğrusal modellerin örneklem dışı tahmin yeteneđini RMSE ölçüsüyle karşılaştırmışlardır. Sonuçta her iki endeks için örneklem dışı YSA tahminlerinin doğrusal tahminlerden daha başarılı olduđu ifade edilmiş olup YSA tahminlerinin iki endeksin tahmini için de doğrusal modelin tahmin

hatalarını açıklayabildiğini ancak doğrusal modelin YSA tahmin hatalarını her iki endeks için açıklayamadığını belirtilmiştir.



ÜÇÜNCÜ BÖLÜM

BİST ELEKTRİK ENDEKSİNDE YER ALAN ŞİRKETLERİN HİSSE SENEDİ FİYAT TAHMİNİNDE YAPAY SİNİR AĞLARI UYGULAMASI

Çalışmanın bu bölümünde araştırmanın amacı ve önemi açıklanacaktır. BİST Elektrik Endeksi ve bu endekste yer alan hisse senetlerinin fiyatları Yapay Sinir Ağları Yöntemiyle analiz edilerek tahmin için kullanılan değişkenler, oluşturulan modeller ve özellikleri ile ulaşılan sonuçlar konusunda bilgiler verilecektir.

3.1. Çalışmanın Amacı ve Önemi

Teknolojik gelişmeler, sanayi üretim ve tüketim kapasite artışları ve insanların hayat kalitesini artıran birçok unsur için enerji kaynaklarının önemli bir faktör olması enerji tüketiminde artışlara sebep olmakta ve enerjinin önemini ön plana çıkarmaktadır. Özellikle elektrik enerjisi bütün teknolojik cihazlar için önemli bir hâle gelmiştir.

Enerji ve Tabii Kaynaklar Bakanlığı verilerine göre Türkiye’de 2023 yılında elektrik tüketimi 330,3 TWh olmuştur. Türkiye Ulusal Enerji Planı çalışmasının sonuçlarına göre bu rakamın 2025 yılı için 380,2 TWh, 2030 yılı için 455,3 TWh, 2035 yılında ise 510,5 TWh seviyesine ulaşması beklenmektedir. Diğer taraftan 2023 yılındaki elektrik üretimi ise 326,3 TWh olmuş bunun %10,4’ünün rüzgar enerjisinden, %5,7’si güneş enerjisinden, %3,4’ünün jeotermal enerjiden, %19,6’sının hidrolik enerjiden, %21,4’ünün doğal gazdan, %36,3’ünün kömürden, %3,2’sinin diğer kaynaklardan üretildiği belirtilmiştir. (<https://enerji.gov.tr/bilgi-merkezi-enerji-elektrik>, Erişim Tarihi: 9.07.2024). Buna bağlı olarak son dönemlerde özellikle güneş, rüzgâr, biyokütle gibi doğal ve yenilenebilir enerji kaynakları kullanılarak elektrik enerjisi üretimi yatırımcılar tarafından da ilgi görmeye başlamıştır. Bu durum enerji şirketleri sayısında da artış gözlemlenmesine sebep olmuştur. Bu şirketlerden bazılarının payları borsada halka arz edilmiştir ve hisse senedine yatırım yapan yatırımcılar tarafından ilgi görmektedir.

Hisse senetlerinin gelecekteki fiyatlarının tahmin edilmesi yatırımcıların hisse senetlerinin getirisinde kâr veya zarar beklentisini belirlemesi açısından önemlidir. Gelecekteki fiyat tahminine göre hisse senedinin zarar edeceği beklentisindeki bir yatırımcı başka bir hisse senedine yatırım yapmaya yönelebilir. Bu sebeple bu araştırmanın amacı, günümüzde çok popüler bir konu olan Yapay Zekânın bir alanı olan Yapay Sinir Ağları ile hisse senetlerinin fiyatlarını etkilediği düşünülen değişkenler kullanılarak BİST Elektrik Endeksi ve bu endekste yer alan şirketlerin hisse senetleri fiyatlarının tahmin edilmesidir.

3.2. Veri ve Değişkenler

Literatür incelendiğinde hisse senetlerinin fiyatlarını hangi değişkenlerin etkilediğine dair yapılan birçok ampirik çalışma vardır. Bunlardan birkaçını şu şekilde açıklayabiliriz:

Ünlü (2023), BİST Elektrik ile TL/Dolar kuru, brent petrol varil fiyatı, sanayi üretim endeksi, kredi temerrüt takasları, 3 aylık mevduat faiz oranı gibi makroekonomik göstergeler arasındaki ilişkiyi kısa ve uzun dönem için incelemiştir. Çalışmada brent petrolün kısa ve uzun dönemde enerji sektöründe anlamsız olduğu belirtilmiştir. Yazar, brent petrolün petrokimya ve petrol endüstrisinde hammadde sağladığı, elektrik üretiminde ise daha çok nükleer enerji, güneş- rüzgar enerjileri, doğalgaz, hidroelektrik vb. kaynakların kullanıldığını ifade etmiştir. Diğer taraftan CDS'nin (kredi temerrüt takası) endeks değerinde anlamlı ve negatif etkisi olduğunu belirtmiştir. TL/Dolar kurunun enerji endeksi üzerinde anlamlı ve pozitif etkisinin olduğunu bunun TL/Dolar kuru arttığında enerji fiyatlarında da artış olması durumunu gösterdiğini açıklamıştır.

Şahin ve Özkan (2018), yaptıkları çalışmada Türkiye'ye ait kredi temerrüt takası (CDS), Dolar/TL Euro/TL döviz kurları ve BİST 100 Endeksi arasındaki ilişkiyi kısa ve uzun vadede test etmişlerdir. BİST 100 ve kredi temerrüt takası arasında çift yönlü nedensellik ilişkisi bulunurken, BİST 100 ile Dolar/TL, Euro/TL arasında nedensellik ilişkisi bulunamadığı belirtilmektedir.

Kuzu (2017), yaptığı çalışmada Borsa İstanbul'daki yedi endeks (BİST 100, BİST 30, BİST Elektrik, BİST Kimya, BİST Sınai, BİST Teknoloji ve BİST Ulaştırma) ve bu endekslerle ilgili olduğu düşünülen petrol fiyatları, faiz oranları, üretici fiyat endeksi (ÜFE), sanayi üretim endeksi ve döviz kuru ele alınmıştır. Sonuçta, belirlenen endekslerin puanlarında petrol fiyatlarının etkisinin düşük olduğu, döviz kuru ve faiz oranlarının çoğu endekste güçlü etkisi olduğundan söz edilmiştir. Petrolün ithal edilmesi ve petrol fiyatının Türk ekonomisi ya da borsasından bağımsız belirlendiği düşünüldüğünde bu durumun beklenen bir sonuç olduğunu

ifade eden yazar, literatürde petrolün hisse senedi fiyatlarını etkilediğini ifade eden çalışmalarında bulunduğunu belirtmiştir. Yazar, bu durumun petrolü ithal eden ve ihraç eden ülkeler için ayrı ayrı değerlendirilmesi gerektiğini anlatmaktadır.

Kendirli ve Çankaya (2016), BİST 100 ve BİST Ulaştırma Endeksleri ile ham petrol varil fiyatları arasındaki nedensellik ilişkisini incelemiştir. Çalışmada Granger Nedensellik Testi yardımıyla değişkenler arasındaki nedensellik ilişkisini analiz etmişlerdir. Sonuçta BİST 100'ün BİST Ulaştırma ve ham petrol varil fiyatının nedeni olduğu ve BİST 100'den diğer değişkenlere doğru tek yönlü olduğu belirtilmiştir. Diğer taraftan BİST Ulaştırma endeksinin ham petrol varil fiyatının nedeni olduğu yani ulaştırma endeksinde bir fiyat değişimi olduğunda ham petrol varil fiyatını da etkilediği anlatılmaktadır.

Aksoy ve Topçu (2013), altının enflasyon ve hisse senedi arasındaki ilişkiyi çeşitli analizler ile incelemiştir. Yapılan Regresyon Analizi sonucu altın getirisi ile üretici fiyat endeksi (ÜFE) bazlı hesaplanmış enflasyon ile pozitif bir ilişki olduğu, yine altın getirisi ile hisse senedi getirileri arasında negatif ilişki olduğu belirtilmektedir. Engle- Granger Eşbütünleşme testi sonucu altın ile ÜFE ve TÜFE arasında nedensellik ilişkisinin tespit edildiği, Granger Nedensellik Testi sonucu devlet iç borçlanma senetleri, hisse senedi fiyatları ve TÜFE'den altına, altından üretici fiyat endeksine tek yönlü nedensellik ilişkisi tespit edildiği belirtilmektedir. Uzun dönemli sonuçlara göre altının hisse senetleri, devlet iç borçlanma senetleri, ÜFE ve TÜFE ile nedensellik ilişkisi olduğu açıklanmıştır. Altın ÜFE'yi etkilerken; TÜFE, devlet iç borçlanma senetleri ve hisse senetleri ise altın fiyatlarını etkilemektedir.

Özer vd. (2011) İMKB 100 Endeksi ve para arzı, faiz oranı, dış ticaret dengesi, sanayi üretim endeksi, altın fiyatı, tüketici fiyat endeksi, döviz kuru değişkenleri arasında ilişki olup olmadığını test etmişlerdir. Çalışmada En Küçük Kareler Tahmin Yöntemi, Granger Nedensellik Testi, Johansen- Juselius Eşbütünleşme Testi, Vector Error Correction (VEC) modelleri kullanılmıştır. Yapılan analizlere göre En Küçük Kareler Tahmin Yöntemi sonucunda tüm değişkenler (para arzı, faiz oranı, dış ticaret dengesi, sanayi üretim endeksi, altın fiyatı, tüketici fiyat endeksi, döviz kuru) ile İMKB 100 arasında anlamlı ilişki olduğu açıklanmıştır. Johansen- Juselius Eşbütünleşme Testi sonucunda hisse senedi fiyatı ile tüketici fiyat endeksi, faiz oranı, dış ticaret dengesi, para arzı, sanayi üretim endeksi arasında uzun dönemli ilişki bulunduğu belirtilmektedir. Granger Nedensellik Testi sonucunda döviz kuru değişkeni dışında bütün değişkenlerin hisse senedi fiyatları ile tek yönlü nedensellik bulunmuştur. Tüketici fiyat endeksi, dış ticaret dengesi, faiz oranı hisse senetlerinin nedenini oluştururken; altın, para arzı, sanayi üretim endeksinin tek yönlü olarak hisse senedi

fiyatlarından etkilendiği ifade edilmiştir. Vector Error Correction (VEC) modelinden ulaşılan hisse senedi fiyatları varyans ayırma sonuçlarından hisse senedi fiyatlarının en çok kendi şoklarından, daha sonra ise sırasıyla dış ticaret dengesi, sanayi üretim endeksi, tüketici fiyat endeksi, faiz oranı, para arzı, altın fiyatı, döviz kuru ve değişkenlerinin şoklarından etkilendiği ifade edilmiştir. Araştırmada dört farklı analiz sonucunda araştırma için belirlenen dönemde hisse senetleri fiyatları ve makroekonomik değişkenlerin arasında farklı derecelerde de olsa bir ilişki olduğu belirtilmiştir.

Akcan ve Kartal (2011)'de İMKB Sigorta Endeksi'de yer alan hisse senetleri fiyatlarının tahmini için Yapay Sinir Ağları Yöntemini kullanmışlardır. Çalışmada hisse senedini tahmin etmek için 12 bağımsız değişken kullanılmış bunlardan 4 tanesi İMKB günlük kapanış, TÜFE, TCMB dolar efektif satış kuru ve TCMB günlük Cumhuriyet altını verileridir. Diğer 8 bağımsız değişken ise fiyat/ kazanç oranı, piyasa değeri/ defter değeri oranı, özsermaye kârlılığı, aktif kârlılığı, alınan primler/ toplam aktifler, alınan net prim büyüme hızı oranı, hisse başına kâr tutarı ve net kâr/ alınan primler oranıdır. Analiz sonucunda başarılı tahminlere ulaşıldığı belirtilmektedir.

Araştırmada Ocak 2004- Mart 2024 dönemlerine ait Euro, Dolar, Gram Altın, Brent Petrol, BİST 100 Endeksi, Tüketici Fiyat Endeksi (TÜFE), BİST Elektrik Endeksi ve Akenerji, Aksu Enerji, Ayen Enerji ve Zorlu Enerji'ye ait hisse senetlerine ait olmak üzere her biri 243 adet aylık verilerden oluşan 11 değişken kullanılmıştır. BİST Elektrik Endeksi'nde hâlihazırda 32 şirket bulunmaktadır. Çalışmada, uzun bir dönem için YSA analizinin tahmin yeteneğinin incelenmesi amacıyla Ocak 2004- Mart 2024 dönemine ait aylık veriler kullanılmıştır. BİST Elektrik Endeksi'ndeki Akenerji, Aksu Enerji, Ayen Enerji ve Zorlu Enerji dışındaki diğer hisse senetlerinin belirlenen tarihteki bazı dönemlerde verileri bulunmadığı için araştırmaya dâhil edilmemiştir. Çalışmada tüketici fiyat endeks rakamları (2003=100) verilerine Ocak 2004- Ağustos 2020 yılına ait verilere 16.09.2020 tarihinde Türkiye İstatistik Kurumu'nun (TÜİK) sitesi (<https://data.tuik.gov.tr>); Eylül 2020- Mart 2024 tarihleri için gerekli verilere ise 26.04.2024 'de yine TÜİK'in sitesi vasıtası ile ulaşılmıştır. Euro, Dolar, Gram Altın, Brent Petrol, BİST 100 Endeksi ve BİST Elektrik Endeksi verileri ise 26.04.2024 tarihinde bir veri sağlayıcı şirketi olan MATRİKS'ten alınmıştır.

Tablo 3.1: Analizdeki Hisse Senetlerine Ait Endeks Adı-Şirket Unvanları ve Kodlar

ENDEKS ADI- ŞİRKET UNVANI	KODU
BİST100 ENDEKSİ	XU100
BİST ELEKTRİK ENDEKSİ	XELKT
AKENERJİ ELEKTRİK ÜRETİM A.Ş.	AKENR
AKSU ENERJİ VE TİCARET A.Ş.	AKSUE
AYEN ENERJİ A.Ş.	AYEN
ZORLU ENERJİ ELEKTRİK ÜRETİM A.Ş.	ZOREN

3.3. Analiz Yöntemi ve Yapay Sinir Ağları Modellerinin Oluşturulması

Analizlerde kullanılacak veriler aşırı büyük veya küçük değerlere sahip olabilir. Verilerdeki bu değişkenliği gidererek düzenlemek, sinir ağının eğitim ve test aşamasının daha başarılı olmasını sağlamak amacıyla verilere normalizasyon yapılabilir. Kaastra ve Boyd (1996, s. 220) verinin ön işleminin sinir ağı modelinin öğrenmesini sağlamak amacıyla verilerdeki gürültüyü azaltmak, değişkenlerin dağılımda düzenleme yapmak, önemli ilişkilere vurgu yapmak ve eğilimleri belirlemek için sinir ağına dahil edilecek değişkenlerde yapılan dönüştürme işlemini ifade ettiğini belirtmiştir. Bu amaçla araştırmada kullanılacak değişkenler Microsoft Office Excel programı yardımı ile düzenlenip verilerin doğal logaritması alınarak verilerin ön işlemleri (normalizasyonu) sağlanmıştır. Aynı zamanda değişkenlerin normalizasyonu yapılmadan ham hali ile aynı analizler yapılmıştır. Sonuç olarak, çalışmada hem normalizasyonu yapılmış hem de normalizasyonu yapılmamış veriler için aynı analizler 2 kez uygulanmıştır. Yapay Sinir Ağları analizi için ise MATLAB R2024a programı kullanılmıştır.

Analizde Euro, Dolar, Gram Altın, Brent Petrol, XU100 ve TÜFE verileri bağımsız değişken; XELKT Endeksi, AKENR, AKSUE, AYEN ve ZOREN hisse senetleri verileri ise bağımlı değişken olarak YSA modelleri oluşturulmuştur. Fiyatları tahmin edilmek istenen 5 bağımlı değişkendeki etkisini gözlemlemek amacıyla bağımlı değişkenlerin her biri ayrı ayrı analiz edilmiştir. Yani her bir YSA modelinde 6 bağımsız değişken ve 1 bağımlı değişken bulunmaktadır. Zhang vd. (1998, s. 50), analizde eğitim ve test oranı belirlenmesinde

literatürde belirli bir kural olmadığını ve çoğu yazarın %90 eğitim %10 test, %80 eğitim %20 test, %70 eğitim %30 test kuralına göre seçtiklerini bazı yazarların ise bu kriteri kendi problemlerine göre seçtiklerini belirtmişlerdir. Bu çalışmada ise veriler rastgele olacak şekilde hem %80'i eğitim %20'si test için ayrılmış hem de %90'ı eğitim %10'u test için ayrılmış olarak iki şekilde eğitilmiştir.

YSA oluşturulurken model seçimi, gizli katman sayısı, katmanlardaki nöron sayısı ve bunlar gibi parametrelerin seçiminde belli bir kuralın bulunmaması bu parametrelerin belirlenmesinin deneme yanılma yoluyla yapılmasını gerektirirken, eğitimin uzun zaman alabilmesi gibi dezavantaja sebep olur (Karacameydan, 2009, ss. 80-81). Araştırmada MATLAB programı ile ileri beslemeli (feedforward) YSA modelleri oluşturulmuştur. Eğitim fonksiyonu olarak Levenberg-Marquardt (LM), Bayesian Regularization (BR) ve Scaled Conjugate Gradient (SCG) geri yayımlı algoritmalar kullanılmış olup; bir bağımlı değişkene logaritması alınarak normalizasyonu yapılmış veriler ve ham veriler ve hem %80 eğitim %20 test oranı hem de %90 eğitim %10 test oranı olmak üzere 36 analiz uygulanarak bütün bağımlı değişkenler için hesaplandığında toplam 180 analiz yapılmıştır. Tablo 3.2.'de analiz için oluşturulan YSA modellerinin bilgileri bulunmaktadır. Tüm bağımlı değişkenlerin analizinde ilgili kodlar ikinci kez çalıştırılmış ve ikinci analiz sonuçlarına göre yorumlamalar yapılmıştır. Bunun yanı sıra program, Epoch sayısı maksimum 1000, performans ölçüsü ise MSE (Mean Squared Error) yani Ortalama Kare Hata olarak belirlenmiştir. Sonuçların yorumlanmasında Regresyon analizindeki "Toplam R değeri" ve analiz performansı "MSE" değerleri kıyaslanmıştır.

Tablo 3.2: Yapay Sinir Ağı Modeli ile İlgili Bilgiler

Eğitim Fonksiyonu	Gizli Katman Sayısı	Gizli Katmanlarda Yer Alan Nöron Sayısı	Birinci Gizli Katmandaki Transfer Fonksiyonu	İkinci Gizli Katmandaki Transfer Fonksiyonu	Üçüncü Gizli Katmandaki Transfer Fonksiyonu
Levenberg-Marquardt (LM)	1	5	Hiperbolik Tanjant Sigmoid (tansig)	---	---
Levenberg-Marquardt (LM)	2	5 -10	Hiperbolik Tanjant Sigmoid (tansig)	Logaritmik Sigmoid (logsig)	---
Levenberg-Marquardt (LM)	3	5-10-15	Hiperbolik Tanjant Sigmoid (tansig)	Logaritmik Sigmoid (logsig)	Doğrusal Transfer Fonksiyonu (Purelin)
Bayesian Regularization (BR)	1	5	Hiperbolik Tanjant Sigmoid (tansig)	---	---
Bayesian Regularization (BR)	2	5-10	Hiperbolik Tanjant Sigmoid (tansig)	Logaritmik Sigmoid (logsig)	---
Bayesian Regularization (BR)	3	5-10-15	Hiperbolik Tanjant Sigmoid (tansig)	Logaritmik Sigmoid (logsig)	Doğrusal Transfer Fonksiyonu (Purelin)
Scaled Conjugate Gradient (SCG)	1	5	Hiperbolik Tanjant Sigmoid (tansig)	---	---
Scaled Conjugate Gradient (SCG)	2	5-10	Hiperbolik Tanjant Sigmoid (tansig)	Logaritmik Sigmoid (logsig)	---
Scaled Conjugate Gradient (SCG)	3	5-10-15	Hiperbolik Tanjant Sigmoid (tansig)	Logaritmik Sigmoid (logsig)	Doğrusal Transfer Fonksiyonu (Purelin)

MSE değeri sıfıra yakın oldukça hatanın daha az olduğu söylenebilir. Bu sebeple MSE değeri en küçük olan model daha başarılıdır. Ortalama Kare Hata (MSE) ise şu şekilde hesaplanmaktadır:

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

y_i = Gerçekleşen değeri,

$\hat{y}_i$ = Tahmin edilen değeri,

n = Örneklem sayısını ifade etmektedir.

Ayrıca diğer bir önemli kriter olan R değeri de hedeflenen değerle analiz sonucu elde edilen değer arasındaki ilişkiyi göstermektedir. R değeri 1'e ne kadar yakın olursa analizin başarılı olduğunu göstermektedir. Tüm bilgilere göre analiz sonucu değerlendirme yaparken MSE değeri en düşük, Toplam R değeri en yüksek model bulunmaya çalışılacaktır.

3.4. Analiz Sonuçları

Çalışmada öncelikle AKENR, AKSUE, AYEN, ZOREN VE XELKT Endeksi hisse senedi fiyatlarının normalizasyon yapılmamış şekliyle analiz yapılmıştır.

3.4.1. Ham Veriler İçin %80 Eğitim %20 Test Oranına Göre Sonuçlar

Tablo 3.3: AKENR Hisse Senedi Analiz Sonucu

Eğitim Fonksiyonu	Gizli Katman-Nöron Sayısı	Eğitim Değeri (R)	Doğrulama Değeri (R)	Test Değeri (R)	Toplam (R)	MSE Değeri
Levenberg-Marquardt	5	0.9724	0.97239	0.78826	0.96585	0.1119
Bayesian Regularization	5	0.98192	---	0.85648	0.95975	0.1334
Scaled Conjugate Gradient	5	0.8351	0.91036	0.74188	0.83558	0.5012

Eğitim Fonksiyonu	Gizli Katman-Nöron Sayısı	Eğitim Değeri (R)	Doğrulama Değeri (R)	Test Değeri (R)	Toplam (R)	MSE Değeri
Levenberg-Marquardt	5-10	0.97423	0.80991	0.9361	0.96719	0.1069
Bayesian Regularization	5-10	0.99787	---	0.97482	0.99615	0.0128
Scaled Conjugate Gradient	5-10	0.83715	0.66319	0.93248	0.85176	0.4552

Eğitim Fonksiyonu	Gizli Katman-Nöron Sayısı	Eğitim Değeri (R)	Doğrulama Değeri (R)	Test Değeri (R)	Toplam (R)	MSE Değeri
Levenberg-Marquardt	5-10-15	0.92434	0.66523	0.91048	0.91132	0.2799
Bayesian Regularization	5-10-15	3.3132e-31	---	8.4658e-31	5.7372e-31	4.5585
Scaled Conjugate Gradient	5-10-15	0.68876	0.84797	0.70046	0.70766	0.8615

Tablo 3.3.'de AKENR hisse senedi için yapılan analiz sonuçlarını incelediğimizde 5 nöron bulunan 1 gizli katmanlı modeller içinde en iyi sonuca Levenberg-Marquardt fonksiyonu ile oluşturulan model “Toplam R” değeri 0.96585 ve “MSE” değeri 0.1119 ile ulaşmıştır. Nöron sayısı ilk katmanda 5, ikinci katmanda 10 olarak belirlenen 2 gizli katmanlı modeller içinde ise 0.99615 toplam R ve 0.0128 MSE değeri ile Bayesian Regularization fonksiyonu; Nöron sayıları 5-10-15 olan 3 gizli katmanlı modellerden ise 0.91132 toplam R ve 0.2799 MSE değeri ile Levenberg- Marquardt fonksiyonu başarılı olmuştur. AKENR hisse senedine ait ham verilerle oluşturulan ve Tablo 3.3.'de gösterilen tüm modeller içinde en başarılı model 2 gizli katmanlı modeller içinde yer alan 0.99615 toplam R ve 0.0128 MSE değeri ile Bayesian Regularization fonksiyonu ile oluşturulan modeldir.

Tablo 3.4: AKSUE Hisse Senedi Analiz Sonucu

Eğitim Fonksiyonu	Gizli Katman-Nöron Sayısı	Eğitim Değeri (R)	Doğrulama Değeri (R)	Test Değeri (R)	Toplam (R)	MSE Değeri
Levenberg-Marquardt	5	0.99559	0.99461	0.97769	0.99123	0.6654
Bayesian Regularization	5	0.99922	---	0.9273	0.98598	0.9611
Scaled Conjugate Gradient	5	0.96632	0.96332	0.9842	0.96514	2.3535

Eğitim Fonksiyonu	Gizli Katman-Nöron Sayısı	Eğitim Değeri (R)	Doğrulama Değeri (R)	Test Değeri (R)	Toplam (R)	MSE Değeri
Levenberg-Marquardt	5-10	0.99791	0.99529	0.97964	0.99381	0.4393
Bayesian Regularization	5-10	0.99985	---	0.97851	0.99551	0.3284
Scaled Conjugate Gradient	5-10	0.98435	0.97748	0.99075	0.98409	1.0889

Eğitim Fonksiyonu	Gizli Katman-Nöron Sayısı	Eğitim Değeri (R)	Doğrulama Değeri (R)	Test Değeri (R)	Toplam (R)	MSE Değeri
Levenberg-Marquardt	5-10-15	0.99953	0.99821	0.99487	0.99756	0.1886
Bayesian Regularization	5-10-15	0.99944	---	0.90981	0.9741	1.7840
Scaled Conjugate Gradient	5-10-15	0.94903	0.99136	0.98537	0.95178	4.4514

Tablo 3.4.'de AKSUE hisse senedi için yapılan analiz sonuçlarını incelediğimizde 5 nöron bulunan 1 gizli katmanlı modeller içinde en iyi sonuca Levenberg-Marquardt fonksiyonu ile oluşturulan model “Toplam R” değeri 0.99123 ve “MSE” değeri 0.6654 ile ulaşmıştır. Nöron sayısı ilk katmanda 5, ikinci katmanda 10 olarak belirlenen 2 gizli katmanlı modeller içinde ise 0.99551 toplam R ve 0.3284 MSE değeri ile Bayesian Regularization fonksiyonu; Nöron sayıları 5-10-15 olan 3 gizli katmanlı modellerden ise 0.99756 toplam R ve 0.1886 MSE değeri ile Levenberg-Marquardt fonksiyonu başarılı olmuştur. AKSUE hisse senedine ait ham

verilerle oluşturulan ve Tablo 3.4.’de gösterilen tüm modeller içinde en başarılı model 3 gizli katmanlı modeller içinde yer alan 0.99756 toplam R ve 0.1886 MSE değeri ile Levenberg-Marquardt fonksiyonu ile oluşturulan modeldir.

Tablo 3.5: AYEN Hisse Senedi Analiz Sonucu

Eğitim Fonksiyonu	Gizli Katman-Nöron Sayısı	Eğitim Değeri (R)	Doğrulama Değeri (R)	Test Değeri (R)	Toplam (R)	MSE Değeri
Levenberg-Marquardt	5	0.99188	0.98896	0.96237	0.98944	1.5245
Bayesian Regularization	5	0.99776	---	0.99452	0.99558	0.6736
Scaled Conjugate Gradient	5	0.94553	0.94452	0.95819	0.94558	7.6000

Eğitim Fonksiyonu	Gizli Katman-Nöron Sayısı	Eğitim Değeri (R)	Doğrulama Değeri (R)	Test Değeri (R)	Toplam (R)	MSE Değeri
Levenberg-Marquardt	5-10	0.98743	0.98572	0.99046	0.98684	2.2336
Bayesian Regularization	5-10	0.99986	---	0.95594	0.99071	1.3834
Scaled Conjugate Gradient	5-10	0.95653	0.97235	0.93804	0.95484	6.0906

Eğitim Fonksiyonu	Gizli Katman-Nöron Sayısı	Eğitim Değeri (R)	Doğrulama Değeri (R)	Test Değeri (R)	Toplam (R)	MSE Değeri
Levenberg-Marquardt	5-10-15	0.99322	0.8676	0.84004	0.90512	18.5085
Bayesian Regularization	5-10-15	0.99829	---	0.97105	0.99473	0.7457
Scaled Conjugate Gradient	5-10-15	0.95746	0.99099	0.97174	0.95152	6.8268

Tablo 3.5.’de AYEN hisse senedi için yapılan analiz sonuçlarını incelediğimizde 5 nöron bulunan 1 gizli katmanlı modeller içinde en iyi sonuca Bayesian Regularization fonksiyonu ile oluşturulan model “Toplam R” değeri 0.99558 ve “MSE” değeri 0.6736 ile ulaşmıştır. Nöron sayısı ilk katmanda 5, ikinci katmanda 10 olarak belirlenen 2 gizli katmanlı modeller içinde ise 0.99071 toplam R ve 1.3834 MSE değeri ile Bayesian Regularization fonksiyonu; Nöron sayıları 5-10-15 olan 3 gizli katmanlı modellerden ise 0.99473 toplam R ve 0.7457 MSE değeri ile Bayesian Regularization fonksiyonu başarılı olmuştur. AYEN hisse senedine ait ham verilerle oluşturulan ve Tablo 3.5.’de gösterilen tüm modeller içinde en başarılı model 1 gizli katmanlı modeller içinde yer alan 0.99558 toplam R ve 0.6736 MSE değeri ile Bayesian Regularization fonksiyonu ile oluşturulan modeldir.

Tablo 3.6: ZOREN Hisse Senedi Analiz Sonucu

Eğitim Fonksiyonu	Gizli Katman-Nöron Sayısı	Eğitim Değeri (R)	Doğrulama Değeri (R)	Test Değeri (R)	Toplam (R)	MSE Değeri
Levenberg-Marquardt	5	0.97712	0.98965	0.69503	0.97815	0.0422
Bayesian Regularization	5	0.9915	---	0.98039	0.98806	0.0234
Scaled Conjugate Gradient	5	0.90858	0.9607	0.85881	0.91779	0.1540

Eğitim Fonksiyonu	Gizli Katman-Nöron Sayısı	Eğitim Değeri (R)	Doğrulama Değeri (R)	Test Değeri (R)	Toplam (R)	MSE Değeri
Levenberg-Marquardt	5-10	0.97694	0.98068	0.97411	0.97645	0.0495
Bayesian Regularization	5-10	0.99927	---	0.9736	0.99688	0.0062
Scaled Conjugate Gradient	5-10	0.96107	0.95112	0.90527	0.9469	0.1049

Eğitim Fonksiyonu	Gizli Katman-Nöron Sayısı	Eğitim Değeri (R)	Doğrulama Değeri (R)	Test Değeri (R)	Toplam (R)	MSE Değeri
Levenberg-Marquardt	5-10-15	0.97529	0.27339	0.94591	0.96703	0.1143
Bayesian Regularization	5-10-15	0.99874	---	0.93373	0.9923	0.0151
Scaled Conjugate Gradient	5-10-15	0.97142	0.95882	0.94902	0.96117	0.0749

Tablo 3.6.'da ZOREN hisse senedi için yapılan analiz sonuçlarını incelediğimizde 5 nöron bulunan 1 gizli katmanlı modeller içinde en iyi sonuca Bayesian Regularization fonksiyonu ile oluşturulan model “Toplam R” değeri 0.98806 ve “MSE” değeri 0.0234 ile ulaşmıştır. Nöron sayısı ilk katmanda 5, ikinci katmanda 10 olarak belirlenen 2 gizli katmanlı modeller içinde ise 0.99688 toplam R ve 0.0062 MSE değeri ile Bayesian Regularization fonksiyonu; Nöron sayıları 5-10-15 olan 3 gizli katmanlı modellerden ise 0.9923 toplam R ve 0.0151 MSE değeri ile Bayesian Regularization fonksiyonu başarılı olmuştur. ZOREN hisse senedine ait ham verilerle oluşturulan ve Tablo 3.6.'da gösterilen tüm modeller içinde en başarılı model 2 gizli katmanlı modeller içinde yer alan 0.99688 toplam R ve 0.0062 MSE değeri ile Bayesian Regularization fonksiyonu ile oluşturulan modeldir.

Tablo 3.7: XELKT Endeksi Analiz Sonucu

Eğitim Fonksiyonu	Gizli Katman-Nöron Sayısı	Eğitim Değeri (R)	Doğrulama Değeri (R)	Test Değeri (R)	Toplam (R)	MSE Değeri
Levenberg-Marquardt	5	0.99482	0.99313	0.92051	0.99392	184.4429
Bayesian Regularization	5	0.99885	---	0.99308	0.99571	144.5823
Scaled Conjugate Gradient	5	0.98364	0.99022	0.94418	0.976	712.1393

Eğitim Fonksiyonu	Gizli Katman-Nöron Sayısı	Eğitim Değeri (R)	Doğrulama Değeri (R)	Test Değeri (R)	Toplam (R)	MSE Değeri
Levenberg-Marquardt	5-10	0.99891	0.93861	0.99409	0.99709	84.9611
Bayesian Regularization	5-10	0.99969	---	0.99277	0.99848	44.8285
Scaled Conjugate Gradient	5-10	0.99359	0.99362	0.98206	0.99233	224.1788

Eğitim Fonksiyonu	Gizli Katman-Nöron Sayısı	Eğitim Değeri (R)	Doğrulama Değeri (R)	Test Değeri (R)	Toplam (R)	MSE Değeri
Levenberg-Marquardt	5-10-15	0.99888	0.90585	0.98373	0.97849	672.4056
Bayesian Regularization	5-10-15	0.99978	---	0.99711	0.99936	18.9211
Scaled Conjugate Gradient	5-10-15	0.96266	0.82947	0.97512	0.95723	1.3069e+03

Tablo 3.7.’de XELKT hisse senedi için yapılan analiz sonuçlarını incelediğimizde 5 nöron bulunan 1 gizli katmanlı modeller içinde en iyi sonuca Bayesian Regularization fonksiyonu ile oluşturulan model “Toplam R” değeri 0.99571 ve “MSE” değeri 144.5823 ile ulaşmıştır. Nöron sayısı ilk katmanda 5, ikinci katmanda 10 olarak belirlenen 2 gizli katmanlı modeller içinde ise 0.99848 toplam R ve 44.8285 MSE değeri ile Bayesian Regularization fonksiyonu; Nöron sayıları 5-10-15 olan 3 gizli katmanlı modellerden ise 0.99936 toplam R ve 18.9211 MSE değeri ile Bayesian Regularization fonksiyonu başarılı olmuştur. XELKT hisse senedine ait ham verilerle oluşturulan ve Tablo 3.7.’de gösterilen tüm modeller içinde en başarılı model 3 gizli katmanlı modeller içinde yer alan 0.99936 toplam R ve 18.9211 MSE değeri ile Bayesian Regularization fonksiyonu ile oluşturulan modeldir.

Tablo 3.8. Ham Veriler İçin %80 Eğitim %20 Test Oranına Göre En İyi Analiz Sonuçları

HİSSE SENEDİ	EĞİTİM FONKSİYONU	GİZLİ KATMAN – NÖRON SAYISI	TOPLAM “R”	MSE
BİST ELEKTRİK	Bayesian Regularization	5-10-15	0.99936	18.9211
AKENR	Bayesian Regularization	5-10	0.99615	0.0128
AKSUE	Levenberg-Marquardt	5-10-15	0.99756	0.1886
AYEN	Bayesian Regularization	5	0.99558	0.6736
ZOREN	Bayesian Regularization	5-10	0.99688	0.0062

Tablo 3.8.’ de hisse senetlerine ait %80 eğitim %20 test oranı ile ham verilerle yapılan analizlerin en iyi sonuç alınan “Toplam R” ve “MSE” değerleri bulunmaktadır. Bu tabloya göre Bayesian Regularization fonksiyonunun diğerlerine göre daha başarılı olduğu gözlemlenmiştir.

3.4.2. Ham Veriler İçin %90 Eğitim %10 Test Oranına Göre Sonuçlar

Tablo 3.9: AKENR Hisse Senedi Analiz Sonucu

Eğitim Fonksiyonu	Gizli Katman-Nöron Sayısı	Eğitim Değeri (R)	Doğrulama Değeri (R)	Test Değeri (R)	Toplam (R)	MSE Değeri
Levenberg-Marquardt	5	0.97415	0.96492	0.9101	0.96731	0.1071
Bayesian Regularization	5	0.97896	---	0.96012	0.97803	0.0718
Scaled Conjugate Gradient	5	0.84114	0.83257	0.45422	0.83652	0.4978

Eğitim Fonksiyonu	Gizli Katman-Nöron Sayısı	Eğitim Değeri (R)	Doğrulama Değeri (R)	Test Değeri (R)	Toplam (R)	MSE Değeri
Levenberg-Marquardt	5-10	0.96197	0.93393	0.68723	0.90751	0.3027
Bayesian Regularization	5-10	0.99829	---	0.8636	0.96947	0.1064
Scaled Conjugate Gradient	5-10	0.82759	0.91615	0.89419	0.83468	0.5072

Eğitim Fonksiyonu	Gizli Katman-Nöron Sayısı	Eğitim Değeri (R)	Doğrulama Değeri (R)	Test Değeri (R)	Toplam (R)	MSE Değeri
Levenberg-Marquardt	5-10-15	0.95859	0.95771	0.9356	0.95593	0.1433
Bayesian Regularization	5-10-15	0.99502	---	0.47437	0.95254	0.1658
Scaled Conjugate Gradient	5-10-15	0.82327	0.92118	-0.026993	0.82552	0.5348

Tablo 3.9.'da AKENR hisse senedi için yapılan analiz sonuçlarını incelediğimizde 5 nöron bulunan 1 gizli katmanlı modeller içinde en iyi sonuca Bayesian Regularization fonksiyonu ile oluşturulan model “Toplam R” değeri 0.97803 ve “MSE” değeri 0.0718 ile ulaşmıştır. Nöron sayısı ilk katmanda 5, ikinci katmanda 10 olarak belirlenen 2 gizli katmanlı modeller içinde ise 0.96947 toplam R ve 0.1064 MSE değeri ile Bayesian Regularization fonksiyonu; Nöron sayıları 5-10-15 olan 3 gizli katmanlı modellerden ise 0.95593 toplam R ve 0.1433 MSE değeri ile Bayesian Regularization fonksiyonu başarılı olmuştur. AKENR hisse senedine ait ham verilerle oluşturulan ve Tablo 3.9.'da gösterilen tüm modeller içinde en başarılı model 1 gizli katmanlı modeller içinde yer alan 0.97803 toplam R ve 0.0718 MSE değeri ile Bayesian Regularization fonksiyonu ile oluşturulan modeldir.

Tablo 3.10: AKSUE Hisse Senedi Analiz Sonucu

Eğitim Fonksiyonu	Gizli Katman-Nöron Sayısı	Eğitim Değeri (R)	Doğrulama Değeri (R)	Test Değeri (R)	Toplam (R)	MSE Değeri
Levenberg-Marquardt	5	0.99743	0.99116	0.9798	0.99587	0.2886
Bayesian Regularization	5	0.99922	---	0.99705	0.99791	0.1543
Scaled Conjugate Gradient	5	0.91229	0.93688	0.93661	0.91566	5.5880

Eğitim Fonksiyonu	Gizli Katman-Nöron Sayısı	Eğitim Değeri (R)	Doğrulama Değeri (R)	Test Değeri (R)	Toplam (R)	MSE Değeri
Levenberg-Marquardt	5-10	0.9964	0.98702	0.99612	0.99449	0.4222
Bayesian Regularization	5-10	0.99964	---	0.99794	0.99955	0.0310
Scaled Conjugate Gradient	5-10	0.98921	0.99275	0.90622	0.98697	0.8940

Eğitim Fonksiyonu	Gizli Katman-Nöron Sayısı	Eğitim Değeri (R)	Doğrulama Değeri (R)	Test Değeri (R)	Toplam (R)	MSE Değeri
Levenberg-Marquardt	5-10-15	0.99762	0.99693	0.99273	0.99551	0.3271
Bayesian Regularization	5-10-15	0.99979	---	0.98857	0.99534	0.3397
Scaled Conjugate Gradient	5-10-15	0.97286	0.94562	0.99514	0.96705	2.2765

Tablo 3.10.'da AKSUE hisse senedi için yapılan analiz sonuçlarını incelediğimizde 5 nöron bulunan 1 gizli katmanlı modeller içinde en iyi sonuca Bayesian Regularization fonksiyonu ile oluşturulan model “Toplam R” değeri 0.99791 ve “MSE” değeri 0.1543 ile ulaşmıştır. Nöron sayısı ilk katmanda 5, ikinci katmanda 10 olarak belirlenen 2 gizli katmanlı modeller içinde ise 0.99955 toplam R ve 0.0310 MSE değeri ile Bayesian Regularization fonksiyonu; Nöron sayıları 5-10-15 olan 3 gizli katmanlı modellerden ise 0.99551 toplam R ve 0.3271 MSE değeri ile Levenberg-Marquardt fonksiyonu başarılı olmuştur. AKSUE hisse senedine

ait ham verilerle oluşturulan ve Tablo 3.10.'da gösterilen tüm modeller içinde en başarılı model 2 gizli katmanlı modeller içinde yer alan 0.99955 toplam R ve 0.0310 MSE değeri ile Bayesian Regularization fonksiyonu ile oluşturulan modeldir.

Tablo 3.11: AYEN Hisse Senedi Analiz Sonucu

Eğitim Fonksiyonu	Gizli Katman-Nöron Sayısı	Eğitim Değeri (R)	Doğrulama Değeri (R)	Test Değeri (R)	Toplam (R)	MSE Değeri
Levenberg-Marquardt	5	0.99497	0.99642	0.9852	0.98655	1.9485
Bayesian Regularization	5	0.99793	---	0.99085	0.99723	0.3828
Scaled Conjugate Gradient	5	0.96386	0.97151	0.9682	0.96388	4.9026

Eğitim Fonksiyonu	Gizli Katman-Nöron Sayısı	Eğitim Değeri (R)	Doğrulama Değeri (R)	Test Değeri (R)	Toplam (R)	MSE Değeri
Levenberg-Marquardt	5-10	0.99468	0.9857	0.95707	0.99407	0.8144
Bayesian Regularization	5-10	0.99975	---	0.94786	0.99088	1.2740
Scaled Conjugate Gradient	5-10	0.98246	0.9497	0.97251	0.97553	3.3469

Eğitim Fonksiyonu	Gizli Katman-Nöron Sayısı	Eğitim Değeri (R)	Doğrulama Değeri (R)	Test Değeri (R)	Toplam (R)	MSE Değeri
Levenberg-Marquardt	5-10-15	0.98542	0.98657	0.98946	0.9853	2.3167
Bayesian Regularization	5-10-15	0.99942	---	0.92099	0.99881	0.1646
Scaled Conjugate Gradient	5-10-15	0.95975	0.97086	0.91225	0.95798	5.7573

Tablo 3.11.'de AYEN hisse senedi için yapılan analiz sonuçlarını incelediğimizde 5 nöron bulunan 1 gizli katmanlı modeller içinde en iyi sonuca Bayesian Regularization fonksiyonu ile oluşturulan model “Toplam R” değeri 0.99723 ve “MSE” değeri 0.3828 ile ulaşmıştır. Nöron sayısı ilk katmanda 5, ikinci katmanda 10 olarak belirlenen 2 gizli katmanlı modeller içinde ise 0.99407 toplam R ve 0.8144 MSE değeri ile Levenberg-Marquardt fonksiyonu; Nöron sayıları 5-10-15 olan 3 gizli katmanlı modellerden ise 0.99881 toplam R ve 0.1646 MSE değeri ile Levenberg-Marquardt fonksiyonu başarılı olmuştur. AYEN hisse senedine ait ham verilerle oluşturulan ve Tablo 3.11.'de gösterilen tüm modeller içinde en başarılı model 3 gizli katmanlı modeller içinde yer alan 0.99881 toplam R ve 0.1646 MSE değeri ile Bayesian Regularization fonksiyonu ile oluşturulan modeldir.

Tablo 3.12: ZOREN Hisse Senedi Analiz Sonucu

Eğitim Fonksiyonu	Gizli Katman-Nöron Sayısı	Eğitim Değeri (R)	Doğrulama Değeri (R)	Test Değeri (R)	Toplam (R)	MSE Değeri
Levenberg-Marquardt	5	0.9926	0.97938	0.94955	0.98377	0.0316
Bayesian Regularization	5	0.99153	---	0.98806	0.98696	0.0264
Scaled Conjugate Gradient	5	0.88453	0.97697	0.87903	0.90608	0.1765

Eğitim Fonksiyonu	Gizli Katman-Nöron Sayısı	Eğitim Değeri (R)	Doğrulama Değeri (R)	Test Değeri (R)	Toplam (R)	MSE Değeri
Levenberg-Marquardt	5-10	0.97887	0.98133	0.7454	0.97733	0.0473
Bayesian Regularization	5-10	0.99751	---	0.97503	0.99269	0.0148
Scaled Conjugate Gradient	5-10	0.95682	0.96853	0.75135	0.956	0.0844

Eğitim Fonksiyonu	Gizli Katman-Nöron Sayısı	Eğitim Değeri (R)	Doğrulama Değeri (R)	Test Değeri (R)	Toplam (R)	MSE Değeri
Levenberg-Marquardt	5-10-15	0.98711	0.91761	0.98288	0.9856	0.0280
Bayesian Regularization	5-10-15	0.99691	---	0.93159	0.97697	0.0490
Scaled Conjugate Gradient	5-10-15	0.95667	0.94231	0.98603	0.95667	0.0880

Tablo 3.12.’de ZOREN hisse senedi için yapılan analiz sonuçlarını incelediğimizde 5 nöron bulunan 1 gizli katmanlı modeller içinde en iyi sonuca Bayesian Regularization fonksiyonu ile oluşturulan model “Toplam R” değeri 0.98696 ve “MSE” değeri 0.0264 ile ulaşmıştır. Nöron sayısı ilk katmanda 5, ikinci katmanda 10 olarak belirlenen 2 gizli katmanlı modeller içinde ise 0.99269 toplam R ve 0.0148 MSE değeri ile Bayesian Regularization fonksiyonu; Nöron sayıları 5-10-15 olan 3 gizli katmanlı modellerden ise 0.9856 toplam R ve 0.0280 MSE değeri ile Levenberg-Marquardt fonksiyonu başarılı olmuştur. ZOREN hisse senedine ait ham verilerle oluşturulan ve Tablo 3.12.’de gösterilen tüm modeller içinde en başarılı model 2 gizli katmanlı modeller içinde yer alan 0.99269 toplam R ve 0.0148 MSE değeri ile Bayesian Regularization fonksiyonu ile oluşturulan modeldir.

Tablo 3.13: XELKT Endeksi Analiz Sonucu

Eğitim Fonksiyonu	Gizli Katman-Nöron Sayısı	Eğitim Değeri (R)	Doğrulama Değeri (R)	Test Değeri (R)	Toplam (R)	MSE Değeri
Levenberg-Marquardt	5	0.99745	0.99726	0.93775	0.99728	77.9257
Bayesian Regularization	5	0.99888	---	0.98171	0.99882	33.7356
Scaled Conjugate Gradient	5	0.97917	0.95962	0.97652	0.97826	700.5441

Eğitim Fonksiyonu	Gizli Katman-Nöron Sayısı	Eğitim Değeri (R)	Doğrulama Değeri (R)	Test Değeri (R)	Toplam (R)	MSE Değeri
Levenberg-Marquardt	5-10	0.99975	0.99861	0.9956	0.99899	29.9893
Bayesian Regularization	5-10	0.9997	---	0.99732	0.99902	29.6344
Scaled Conjugate Gradient	5-10	0.98287	0.99456	0.9865	0.98474	437.0258

Eğitim Fonksiyonu	Gizli Katman-Nöron Sayısı	Eğitim Değeri (R)	Doğrulama Değeri (R)	Test Değeri (R)	Toplam (R)	MSE Değeri
Levenberg-Marquardt	5-10-15	0.99774	0.995	0.99746	0.99725	108.4689
Bayesian Regularization	5-10-15	0.99982	---	0.99946	0.99976	7.0449
Scaled Conjugate Gradient	5-10-15	0.9916	0.98229	0.99098	0.98824	336.3629

Tablo 3.13.'de XELKT Endeksi hisse senedi için yapılan analiz sonuçlarını incelediğimizde 5 nöron bulunan 1 gizli katmanlı modeller içinde en iyi sonuca Bayesian Regularization fonksiyonu ile oluşturulan model “Toplam R” değeri 0.99882 ve “MSE” değeri 33.7356 ile ulaşmıştır. Nöron sayısı ilk katmanda 5, ikinci katmanda 10 olarak belirlenen 2 gizli katmanlı modeller içinde ise 0.99902 toplam R ve 29.6344 MSE değeri ile Bayesian Regularization fonksiyonu; Nöron sayıları 5-10-15 olan 3 gizli katmanlı modellerden ise 0.99976 toplam R ve 7.0449 MSE değeri ile Bayesian Regularization fonksiyonu başarılı olmuştur. XELKT Endeksi hisse senedine ait ham verilerle oluşturulan ve Tablo 3.13.'de gösterilen tüm modeller içinde en başarılı model 3 gizli katmanlı modeller içinde yer alan 0.99976 toplam R ve 7.0449 MSE değeri ile Bayesian Regularization fonksiyonu ile oluşturulan modeldir.

Tablo 3.14. Ham Veriler İçin %90 Eğitim %10 Test Oranına Göre En İyi Analiz Sonuçları

HİSSE SENEDİ	EĞİTİM FONKSİYONU	GİZLİ KATMAN – NÖRON SAYISI	TOPLAM “R”	MSE
BİST ELEKTRİK	Bayesian Regularization	5-10-15	0.99976	7.0449
AKENR	Bayesian Regularization	5	0.97803	0.0718
AKSUE	Bayesian Regularization	5-10	0.99955	0.0310
AYEN	Bayesian Regularization	5-10-15	0.99881	0.1646
ZOREN	Bayesian Regularization	5-10	0.99269	0.0148

Tablo 3.14.’de hisse senetlerine ait %90 eğitim %10 test oranı ile ham verilerle yapılan analizlerin en iyi sonuç alınan “Toplam R” ve “MSE” değerleri bulunmaktadır. Bu tabloya göre Bayesian Regularization fonksiyonunun diğerlerine göre daha başarılı olduğu gözlemlenmiştir.

3.4.3. Normalizasyon Yapılmış Veriler İçin %80 Eğitim %20 Test Oranına Göre Sonuçlar

Çalışmanın bu kısmında logaritması alınarak normalizasyonu yapılmış verilerle yapılan analiz sonuçlarına yer verilmiştir.

Tablo 3.15: AKENR Hisse Senedi Analiz Sonucu

Eğitim Fonksiyonu	Gizli Katman-Nöron Sayısı	Eğitim Değeri (R)	Doğrulama Değeri (R)	Test Değeri (R)	Toplam (R)	MSE Değeri
Levenberg-Marquardt	5	0.97754	0.98691	0.94051	0.97431	0.0164
Bayesian Regularization	5	0.98459	---	0.97681	0.98252	0.0111
Scaled Conjugate Gradient	5	0.73751	0.78633	0.71439	0.73516	0.1465

Eğitim Fonksiyonu	Gizli Katman-Nöron Sayısı	Eğitim Değeri (R)	Doğrulama Değeri (R)	Test Değeri (R)	Toplam (R)	MSE Değeri
Levenberg-Marquardt	5-10	0.97298	0.94119	0.96432	0.96512	0.0219
Bayesian Regularization	5-10	0.99709	---	0.95832	0.99006	0.0063
Scaled Conjugate Gradient	5-10	0.83389	0.90104	0.79897	0.84024	0.0955

Eğitim Fonksiyonu	Gizli Katman-Nöron Sayısı	Eğitim Değeri (R)	Doğrulama Değeri (R)	Test Değeri (R)	Toplam (R)	MSE Değeri
Levenberg-Marquardt	5-10-15	0.95946	0.96774	0.96105	0.9604	0.0248
Bayesian Regularization	5-10-15	0.99653	---	0.94781	0.98659	0.0086
Scaled Conjugate Gradient	5-10-15	0.81603	0.70786	0.86135	0.8142	0.1093

Tablo 3.15.'de AKENR hisse senedi için yapılan analiz sonuçlarını incelediğimizde 5 nöron bulunan 1 gizli katmanlı modeller içinde en iyi sonuca Bayesian Regularization fonksiyonu ile oluşturulan model “Toplam R” değeri 0.98252 ve “MSE” değeri 0.0111 ile ulaşmıştır. Nöron sayısı ilk katmanda 5, ikinci katmanda 10 olarak belirlenen 2 gizli katmanlı modeller içinde ise 0.99006 toplam R ve 0.0063 MSE değeri ile Bayesian Regularization fonksiyonu; Nöron sayıları 5-10-15 olan 3 gizli katmanlı modellerden ise 0.98659 toplam R ve 0.0086 MSE değeri ile Bayesian Regularization fonksiyonu başarılı olmuştur. AKENR hisse senedine ait normalizasyonu yapılmış verilerle oluşturulan ve Tablo 3.15.'de gösterilen tüm modeller içinde en başarılı model 2 gizli katmanlı modeller içinde yer alan 0.99006 toplam R ve 0.0063 MSE değeri ile Bayesian Regularization fonksiyonu ile oluşturulan modeldir.

Tablo 3.16: AKSUE Hisse Senedi Analiz Sonucu

Eğitim Fonksiyonu	Gizli Katman-Nöron Sayısı	Eğitim Değeri (R)	Doğrulama Değeri (R)	Test Değeri (R)	Toplam (R)	MSE Değeri
Levenberg-Marquardt	5	0.99143	0.98674	0.98104	0.98961	0.0298
Bayesian Regularization	5	0.99211	---	0.98907	0.99154	0.0243
Scaled Conjugate Gradient	5	0.97868	0.98337	0.98475	0.98049	0.0559

Eğitim Fonksiyonu	Gizli Katman-Nöron Sayısı	Eğitim Değeri (R)	Doğrulama Değeri (R)	Test Değeri (R)	Toplam (R)	MSE Değeri
Levenberg-Marquardt	5-10	0.99281	0.9917	0.98986	0.992	0.0231
Bayesian Regularization	5-10	0.9932	---	0.99121	0.99288	0.0205
Scaled Conjugate Gradient	5-10	0.95406	0.91097	0.92893	0.94551	0.1568

Eğitim Fonksiyonu	Gizli Katman-Nöron Sayısı	Eğitim Değeri (R)	Doğrulama Değeri (R)	Test Değeri (R)	Toplam (R)	MSE Değeri
Levenberg-Marquardt	5-10-15	0.99499	0.98688	0.98913	0.99302	0.0201
Bayesian Regularization	5-10-15	0.99776	---	0.99097	0.99643	0.0103
Scaled Conjugate Gradient	5-10-15	0.98481	0.98688	0.98162	0.98461	0.0442

Tablo 3.16.'da AKSUE hisse senedi için yapılan analiz sonuçlarını incelediğimizde 5 nöron bulunan 1 gizli katmanlı modeller içinde en iyi sonuca Bayesian Regularization fonksiyonu ile oluşturulan model “Toplam R” değeri 0.99154 ve “MSE” değeri 0.0243 ile ulaşmıştır. Nöron sayısı ilk katmanda 5, ikinci katmanda 10 olarak belirlenen 2 gizli katmanlı modeller içinde ise 0.99288 toplam R ve 0.0205 MSE değeri ile Bayesian Regularization fonksiyonu; Nöron sayıları 5-10-15 olan 3 gizli katmanlı modellerden ise 0.99643 toplam R ve 0.0103 MSE değeri ile Bayesian Regularization fonksiyonu başarılı olmuştur. AKSUE hisse senedine ait normalizasyonu yapılmış verilerle oluşturulan ve Tablo 3.16.'da gösterilen tüm modeller içinde en başarılı model 3 gizli katmanlı modeller içinde yer alan 0.99643 toplam R ve 0.0103 MSE değeri ile Bayesian Regularization fonksiyonu ile oluşturulan modeldir.

Tablo 3.17: AYEN Hisse Senedi Analiz Sonucu

Eğitim Fonksiyonu	Gizli Katman-Nöron Sayısı	Eğitim Değeri (R)	Doğrulama Değeri (R)	Test Değeri (R)	Toplam (R)	MSE Değeri
Levenberg-Marquardt	5	0.98923	0.99261	0.9743	0.9886	0.0286
Bayesian Regularization	5	0.99383	---	0.99109	0.99309	0.0174
Scaled Conjugate Gradient	5	0.96123	0.98135	0.9598	0.96679	0.0828

Eğitim Fonksiyonu	Gizli Katman-Nöron Sayısı	Eğitim Değeri (R)	Doğrulama Değeri (R)	Test Değeri (R)	Toplam (R)	MSE Değeri
Levenberg-Marquardt	5-10	0.98456	0.98157	0.97736	0.98267	0.0434
Bayesian Regularization	5-10	0.99856	---	0.97581	0.99558	0.0111
Scaled Conjugate Gradient	5-10	0.96324	0.96364	0.956	0.96112	0.0965

Eğitim Fonksiyonu	Gizli Katman-Nöron Sayısı	Eğitim Değeri (R)	Doğrulama Değeri (R)	Test Değeri (R)	Toplam (R)	MSE Değeri
Levenberg-Marquardt	5-10-15	0.99061	0.96408	0.98594	0.98492	0.0388
Bayesian Regularization	5-10-15	0.9984	---	0.99017	0.99697	0.0077
Scaled Conjugate Gradient	5-10-15	0.92707	0.91923	0.95092	0.9301	0.1733

Tablo 3.17.'de AYEN hisse senedi için yapılan analiz sonuçlarını incelediğimizde 5 nöron bulunan 1 gizli katmanlı modeller içinde en iyi sonuca Bayesian Regularization fonksiyonu ile oluşturulan model "Toplam R" değeri 0.99309 ve "MSE" değeri 0.0174 ile ulaşmıştır. Nöron sayısı ilk katmanda 5, ikinci katmanda 10 olarak belirlenen 2 gizli katmanlı modeller içinde ise 0.99558 toplam R ve 0.0111 MSE değeri ile Bayesian Regularization fonksiyonu; Nöron sayıları 5-10-15 olan 3 gizli katmanlı modellerden ise 0.99697 toplam R ve 0.0077 MSE değeri ile Bayesian Regularization fonksiyonu başarılı olmuştur. AYEN hisse senedine ait normalizasyonu yapılmış verilerle oluşturulan ve Tablo 3.17.'de gösterilen tüm modeller içinde en başarılı model 3 gizli katmanlı modeller içinde yer alan 0.99697 toplam R ve 0.0077 MSE değeri ile Bayesian Regularization fonksiyonu ile oluşturulan modeldir.

Tablo 3.18.'de ZOREN hisse senedi için yapılan analiz sonuçlarını incelediğimizde 5 nöron bulunan 1 gizli katmanlı modeller içinde en iyi sonuca Bayesian Regularization fonksiyonu ile oluşturulan model "Toplam R" değeri 0.98359 ve "MSE" değeri 0.0107 ile ulaşmıştır. Nöron sayısı ilk katmanda 5, ikinci katmanda 10 olarak belirlenen 2 gizli katmanlı modeller içinde ise 0.99184 toplam R ve 0.0054 MSE değeri ile Bayesian Regularization fonksiyonu; Nöron sayıları 5-10-15 olan 3 gizli katmanlı modellerden ise 0.99426 toplam R ve 0.0038 MSE değeri ile Bayesian Regularization fonksiyonu başarılı olmuştur. ZOREN hisse senedine

ait normalizasyonu yapılmış verilerle oluşturulan ve Tablo 3.18.'de gösterilen tüm modeller içinde en başarılı model 3 gizli katmanlı modeller içinde yer alan 0.99426 toplam R ve 0.0038 MSE değeri ile Bayesian Regularization fonksiyonu ile oluşturulan modeldir.

Tablo 3.18: ZOREN Hisse Senedi Analiz Sonucu

Eğitim Fonksiyonu	Gizli Katman-Nöron Sayısı	Eğitim Değeri (R)	Doğrulama Değeri (R)	Test Değeri (R)	Toplam (R)	MSE Değeri
Levenberg-Marquardt	5	0.97992	0.98814	0.90589	0.97835	0.0141
Bayesian Regularization	5	0.98473	---	0.97294	0.98359	0.0107
Scaled Conjugate Gradient	5	0.89252	0.85423	0.92169	0.89381	0.0664

Eğitim Fonksiyonu	Gizli Katman-Nöron Sayısı	Eğitim Değeri (R)	Doğrulama Değeri (R)	Test Değeri (R)	Toplam (R)	MSE Değeri
Levenberg-Marquardt	5-10	0.98888	0.94548	0.97347	0.98408	0.0104
Bayesian Regularization	5-10	0.9947	---	0.98019	0.99184	0.0054
Scaled Conjugate Gradient	5-10	0.8624	0.93314	0.8966	0.88113	0.0755

Eğitim Fonksiyonu	Gizli Katman-Nöron Sayısı	Eğitim Değeri (R)	Doğrulama Değeri (R)	Test Değeri (R)	Toplam (R)	MSE Değeri
Levenberg-Marquardt	5-10-15	0.98479	0.98153	0.97005	0.98225	0.0116
Bayesian Regularization	5-10-15	0.99686	---	0.98262	0.99426	0.0038
Scaled Conjugate Gradient	5-10-15	0.82815	0.80053	0.95285	0.86393	0.0839

Tablo 3.19.'da XELKT Endeksi hisse senedi için yapılan analiz sonuçlarını incelediğimizde 5 nöron bulunan 1 gizli katmanlı modeller içinde en iyi sonuca Bayesian Regularization fonksiyonu ile oluşturulan model “Toplam R” değeri 0.9955 ve “MSE” değeri 0.0064 ile ulaşmıştır. Nöron sayısı ilk katmanda 5, ikinci katmanda 10 olarak belirlenen 2 gizli katmanlı modeller içinde ise 0.99863 toplam R ve 0.0026 MSE değeri ile Bayesian Regularization fonksiyonu; Nöron sayıları 5-10-15 olan 3 gizli katmanlı modellerden ise 0.99779 toplam R ve 0.0032 MSE değeri ile Bayesian Regularization fonksiyonu başarılı olmuştur. XELKT Endeksi hisse senedine ait normalizasyonu yapılmış verilerle oluşturulan ve Tablo 3.19.'da gösterilen tüm modeller içinde en başarılı model 2 gizli katmanlı modeller içinde yer alan 0.99863 toplam R ve 0.0026 MSE değeri ile Bayesian Regularization fonksiyonu ile oluşturulan modeldir.

Tablo 3.19: XELKT Endeksi Analiz Sonucu

Eğitim Fonksiyonu	Gizli Katman-Nöron Sayısı	Eğitim Değeri (R)	Doğrulama Değeri (R)	Test Değeri (R)	Toplam (R)	MSE Değeri
Levenberg-Marquardt	5	0.98535	0.98991	0.9498	0.98409	0.0245
Bayesian Regularization	5	0.9959	---	0.99404	0.9955	0.0064
Scaled Conjugate Gradient	5	0.95445	0.97795	0.97021	0.96106	0.0546

Eğitim Fonksiyonu	Gizli Katman-Nöron Sayısı	Eğitim Değeri (R)	Doğrulama Değeri (R)	Test Değeri (R)	Toplam (R)	MSE Değeri
Levenberg-Marquardt	5-10	0.99753	0.99263	0.99469	0.99616	0.0056
Bayesian Regularization	5-10	0.99918	---	0.99648	0.99863	0.0026
Scaled Conjugate Gradient	5-10	0.95703	0.98265	0.96894	0.96633	0.0469

Eğitim Fonksiyonu	Gizli Katman-Nöron Sayısı	Eğitim Değeri (R)	Doğrulama Değeri (R)	Test Değeri (R)	Toplam (R)	MSE Değeri
Levenberg-Marquardt	5-10-15	0.99097	0.96021	0.98391	0.98698	0.0185
Bayesian Regularization	5-10-15	0.99889	---	0.99372	0.99779	0.0032
Scaled Conjugate Gradient	5-10-15	0.94071	0.91369	0.97624	0.95046	0.0710

Tablo 3.20. Normalizasyon Yapılmış Veriler İçin %80 Eğitim %20 Test Oranına Göre En İyi Analiz Sonuçları

HİSSE SENEDİ	EĞİTİM FONKSİYONU	GİZLİ KATMAN – NÖRON SAYISI	TOPLAM “R”	MSE
BİST ELEKTRİK	Bayesian Regularization	5-10	0.99863	0.0026
AKENR	Bayesian Regularization	5-10	0.99006	0.0063
AKSUE	Bayesian Regularization	5-10-15	0.99643	0.0103
AYEN	Bayesian Regularization	5-10-15	0.99697	0.0077
ZOREN	Bayesian Regularization	5-10-15	0.99426	0.0038

Tablo 3.20.’de hisse senetlerine ait %80 eğitim %20 test oranı ile logaritması alınarak normalizasyonu yapılmış verilerle yapılan analizlerin en iyi sonuç alınan “Toplam R” ve “MSE” değerleri bulunmaktadır. Bu tabloya göre Bayesian Regularization fonksiyonunun diğerlerine göre daha başarılı olduğu gözlemlenmiştir.

3.4.4. Normalizasyon Yapılmış Veriler İçin %90 Eğitim %10 Test Oranına Göre Sonuçlar

Çalışmanın bu kısmında logaritması alınarak normalizasyonu yapılmış verilerin %90 eğitim %10 test oranı ile yapılan analiz sonuçlarına yer verilmiştir.

Tablo 3.21: AKENR Hisse Senedi Analiz Sonucu

Eğitim Fonksiyonu	Gizli Katman-Nöron Sayısı	Eğitim Değeri (R)	Doğrulama Değeri (R)	Test Değeri (R)	Toplam (R)	MSE Değeri
Levenberg-Marquardt	5	0.97445	0.98123	0.94505	0.97268	0.0184
Bayesian Regularization	5	0.98262	---	0.9796	0.9823	0.0112
Scaled Conjugate Gradient	5	0.81516	0.80939	0.64149	0.80627	0.1116

Eğitim Fonksiyonu	Gizli Katman-Nöron Sayısı	Eğitim Değeri (R)	Doğrulama Değeri (R)	Test Değeri (R)	Toplam (R)	MSE Değeri
Levenberg-Marquardt	5-10	0.9815	0.95353	0.96307	0.97391	0.0169
Bayesian Regularization	5-10	0.99667	---	0.96635	0.99501	0.0032
Scaled Conjugate Gradient	5-10	0.77188	0.89622	0.72735	0.79129	0.1191

Eğitim Fonksiyonu	Gizli Katman-Nöron Sayısı	Eğitim Değeri (R)	Doğrulama Değeri (R)	Test Değeri (R)	Toplam (R)	MSE Değeri
Levenberg-Marquardt	5-10-15	0.98386	0.98659	0.98124	0.98412	0.0100
Bayesian Regularization	5-10-15	0.99574	---	0.96315	0.99329	0.0043
Scaled Conjugate Gradient	5-10-15	0.86245	0.90979	0.74223	0.8623	0.0832

Tablo 3.21.'de AKENR hisse senedi için yapılan analiz sonuçlarını incelediğimizde 5 nöron bulunan 1 gizli katmanlı modeller içinde en iyi sonuca Bayesian Regularization fonksiyonu ile oluşturulan model “Toplam R” değeri 0.9823 ve “MSE” değeri 0.0112 ile ulaşmıştır. Nöron sayısı ilk katmanda 5, ikinci katmanda 10 olarak belirlenen 2 gizli katmanlı modeller içinde 0.99501 toplam R ve 0.0032 MSE değeri ile Bayesian Regularization fonksiyonu; Nöron sayıları 5-10-15 olan 3 gizli katmanlı modellerden ise 0.99329 toplam R ve 0.0043 MSE değeri ile Bayesian Regularization fonksiyonu başarılı olmuştur. AKENR hisse senedine ait normalizasyonu yapılmış verilerle oluşturulan ve Tablo 3.21.'de gösterilen tüm modeller içinde en başarılı model 2 gizli katmanlı modeller içinde yer alan 0.99501 toplam R ve 0.0032 MSE değeri ile Bayesian Regularization fonksiyonu ile oluşturulan modeldir.

Tablo 3.22.'de AKSUE hisse senedi için yapılan analiz sonuçlarını incelediğimizde 5 nöron bulunan 1 gizli katmanlı modeller içinde en iyi sonuca Levenberg-Marquardt fonksiyonu ile oluşturulan model “Toplam R” değeri 0.9933 ve “MSE” değeri 0.0194 ile ulaşmıştır. Nöron

sayısı ilk katmanda 5, ikinci katmanda 10 olarak belirlenen 2 gizli katmanlı modeller içinde 0.99816 toplam R ve 0.0054 MSE değeri ile Bayesian Regularization fonksiyonu; Nöron sayıları 5-10-15 olan 3 gizli katmanlı modellerden ise 0.99476 toplam R ve 0.0151 MSE değeri ile Levenberg-Marquardt fonksiyonu başarılı olmuştur. AKSUE hisse senedine ait normalizasyonu yapılmış verilerle oluşturulan ve Tablo 3.22.’de gösterilen tüm modeller içinde en başarılı model 2 gizli katmanlı modeller içinde yer alan 0.99816 toplam R ve 0.0054 MSE değeri ile Bayesian Regularization fonksiyonu ile oluşturulan modeldir.

Tablo 3.22: AKSUE Hisse Senedi Analiz Sonucu

Eğitim Fonksiyonu	Gizli Katman-Nöron Sayısı	Eğitim Değeri (R)	Doğrulama Değeri (R)	Test Değeri (R)	Toplam (R)	MSE Değeri
Levenberg-Marquardt	5	0.9949	0.99048	0.98726	0.9933	0.0194
Bayesian Regularization	5	0.99177	---	0.9795	0.99126	0.0251
Scaled Conjugate Gradient	5	0.97801	0.98975	0.98192	0.98056	0.0555

Eğitim Fonksiyonu	Gizli Katman-Nöron Sayısı	Eğitim Değeri (R)	Doğrulama Değeri (R)	Test Değeri (R)	Toplam (R)	MSE Değeri
Levenberg-Marquardt	5-10	0.99333	0.99043	0.99173	0.99272	0.0211
Bayesian Regularization	5-10	0.99873	---	0.99439	0.99816	0.0054
Scaled Conjugate Gradient	5-10	0.97885	0.97728	0.983	0.97874	0.0608

Eğitim Fonksiyonu	Gizli Katman-Nöron Sayısı	Eğitim Değeri (R)	Doğrulama Değeri (R)	Test Değeri (R)	Toplam (R)	MSE Değeri
Levenberg-Marquardt	5-10-15	0.99503	0.99234	0.99664	0.99476	0.0151
Bayesian Regularization	5-10-15	0.99313	---	0.98388	0.99278	0.0208
Scaled Conjugate Gradient	5-10-15	0.95674	0.94697	0.95468	0.95469	0.1432

Tablo 3.23.’de AYEN hisse senedi için yapılan analiz sonuçlarını incelediğimizde 5 nöron bulunan 1 gizli katmanlı modeller içinde en iyi sonuca Bayesian Regularization fonksiyonu ile oluşturulan model “Toplam R” değeri 0.99201 ve “MSE” değeri 0.0201 ile ulaşmıştır. Nöron sayısı ilk katmanda 5, ikinci katmanda 10 olarak belirlenen 2 gizli katmanlı modeller içinde 0.99692 toplam R ve 0.0082 MSE değeri ile Bayesian Regularization fonksiyonu; Nöron sayıları 5-10-15 olan 3 gizli katmanlı modellerden ise 0.9975 toplam R ve 0.0063 MSE değeri ile Bayesian Regularization fonksiyonu başarılı olmuştur. AYEN hisse senedine ait normalizasyonu yapılmış verilerle oluşturulan ve Tablo 3.23.’de gösterilen tüm modeller içinde en başarılı model 3 gizli katmanlı modeller içinde yer alan 0.9975 toplam R ve 0.0063 MSE değeri ile Bayesian Regularization fonksiyonu ile oluşturulan modeldir.

Tablo 3.23: AYEN Hisse Senedi Analiz Sonucu

Eğitim Fonksiyonu	Gizli Katman-Nöron Sayısı	Eğitim Değeri (R)	Doğrulama Değeri (R)	Test Değeri (R)	Toplam (R)	MSE Değeri
Levenberg-Marquardt	5	0.99252	0.98882	0.97937	0.99039	0.0242
Bayesian Regularization	5	0.99222	---	0.99139	0.99201	0.0201
Scaled Conjugate Gradient	5	0.97269	0.97246	0.96172	0.97077	0.0728

Eğitim Fonksiyonu	Gizli Katman-Nöron Sayısı	Eğitim Değeri (R)	Doğrulama Değeri (R)	Test Değeri (R)	Toplam (R)	MSE Değeri
Levenberg-Marquardt	5-10	0.99477	0.98802	0.98246	0.99338	0.0167
Bayesian Regularization	5-10	0.99844	---	0.99306	0.99692	0.0082
Scaled Conjugate Gradient	5-10	0.93787	0.93627	0.98222	0.94044	0.1673

Eğitim Fonksiyonu	Gizli Katman-Nöron Sayısı	Eğitim Değeri (R)	Doğrulama Değeri (R)	Test Değeri (R)	Toplam (R)	MSE Değeri
Levenberg-Marquardt	5-10-15	0.99448	0.98581	0.98262	0.99268	0.0185
Bayesian Regularization	5-10-15	0.99853	---	0.98731	0.9975	0.0063
Scaled Conjugate Gradient	5-10-15	0.84818	0.85897	0.88318	0.85136	0.3501

Tablo 3.24.'de ZOREN hisse senedi için yapılan analiz sonuçlarını incelediğimizde 5 nöron bulunan 1 gizli katmanlı modeller içinde en iyi sonuca Bayesian Regularization fonksiyonu ile oluşturulan model “Toplam R” değeri 0.98664 ve “MSE” değeri 0.0087 ile ulaşmıştır. Nöron sayısı ilk katmanda 5, ikinci katmanda 10 olarak belirlenen 2 gizli katmanlı modeller içinde 0.9939 toplam R ve 0.0040 MSE değeri ile Bayesian Regularization fonksiyonu; Nöron sayıları 5-10-15 olan 3 gizli katmanlı modellerden ise 0.99408 toplam R ve 0.0039 MSE değeri ile Bayesian Regularization fonksiyonu başarılı olmuştur. ZOREN hisse senedine ait normalizasyonu yapılmış verilerle oluşturulan ve Tablo 3.24.'de gösterilen tüm modeller içinde en başarılı model 3 gizli katmanlı modeller içinde yer alan 0.99408 toplam R ve 0.0039 MSE değeri ile Bayesian Regularization fonksiyonu ile oluşturulan modeldir.

Tablo 3.24: ZOREN Hisse Senedi Analiz Sonucu

Eğitim Fonksiyonu	Gizli Katman-Nöron Sayısı	Eğitim Değeri (R)	Doğrulama Değeri (R)	Test Değeri (R)	Toplam (R)	MSE Değeri
Levenberg-Marquardt	5	0.98037	0.97759	0.91587	0.97851	0.0140
Bayesian Regularization	5	0.98665	---	0.98699	0.98664	0.0087
Scaled Conjugate Gradient	5	0.84717	0.91268	0.90091	0.8608	0.0897

Eğitim Fonksiyonu	Gizli Katman-Nöron Sayısı	Eğitim Değeri (R)	Doğrulama Değeri (R)	Test Değeri (R)	Toplam (R)	MSE Değeri
Levenberg-Marquardt	5-10	0.9806	0.97695	0.99438	0.98118	0.0124
Bayesian Regularization	5-10	0.99544	---	0.94	0.9939	0.0040
Scaled Conjugate Gradient	5-10	0.89609	0.92177	0.94946	0.90543	0.0592

Eğitim Fonksiyonu	Gizli Katman-Nöron Sayısı	Eğitim Değeri (R)	Doğrulama Değeri (R)	Test Değeri (R)	Toplam (R)	MSE Değeri
Levenberg-Marquardt	5-10-15	0.98217	0.97202	0.9847	0.98127	0.0125
Bayesian Regularization	5-10-15	0.9966	---	0.97261	0.99408	0.0039
Scaled Conjugate Gradient	5-10-15	0.90246	0.82825	0.93565	0.8926	0.0697

Tablo 3.25.'de XELKT Endeksi hisse senedi için yapılan analiz sonuçlarını incelediğimizde 5 nöron bulunan 1 gizli katmanlı modeller içinde en iyi sonuca Bayesian Regularization fonksiyonu ile oluşturulan model “Toplam R” değeri 0.9969 ve “MSE” değeri 0.0044 ile ulaşmıştır. Nöron sayısı ilk katmanda 5, ikinci katmanda 10 olarak belirlenen 2 gizli katmanlı modeller içinde 0.999 toplam R ve 0.0014 MSE değeri ile Bayesian Regularization fonksiyonu; Nöron sayıları 5-10-15 olan 3 gizli katmanlı modellerden ise 0.9984 toplam R ve 0.0023 MSE değeri ile Bayesian Regularization fonksiyonu başarılı olmuştur. XELKT Endeksi hisse senedine ait normalizasyonu yapılmış verilerle oluşturulan ve Tablo 3.25.'de gösterilen tüm modeller içinde en başarılı model 2 gizli katmanlı modeller içinde yer alan 0.999 toplam R ve 0.0014 MSE değeri ile Bayesian Regularization fonksiyonu ile oluşturulan modeldir.

Tablo 3.25: XELKT Endeksi Analiz Sonucu

Eğitim Fonksiyonu	Gizli Katman-Nöron Sayısı	Eğitim Değeri (R)	Doğrulama Değeri (R)	Test Değeri (R)	Toplam (R)	MSE Değeri
Levenberg-Marquardt	5	0.99477	0.99498	0.99014	0.99427	0.0082
Bayesian Regularization	5	0.99715	---	0.99499	0.9969	0.0044
Scaled Conjugate Gradient	5	0.9643	0.93788	0.95496	0.9608	0.0548

Eğitim Fonksiyonu	Gizli Katman-Nöron Sayısı	Eğitim Değeri (R)	Doğrulama Değeri (R)	Test Değeri (R)	Toplam (R)	MSE Değeri
Levenberg-Marquardt	5-10	0.99741	0.99263	0.98816	0.99678	0.0045
Bayesian Regularization	5-10	0.99921	---	0.99144	0.999	0.0014
Scaled Conjugate Gradient	5-10	0.96598	0.96484	0.97438	0.96774	0.0449

Eğitim Fonksiyonu	Gizli Katman-Nöron Sayısı	Eğitim Değeri (R)	Doğrulama Değeri (R)	Test Değeri (R)	Toplam (R)	MSE Değeri
Levenberg-Marquardt	5-10-15	0.98714	0.98601	0.97442	0.98627	0.0193
Bayesian Regularization	5-10-15	0.9986	---	0.99511	0.9984	0.0023
Scaled Conjugate Gradient	5-10-15	0.94556	0.97999	0.82856	0.95026	0.0717

Tablo 3.26. Normalizasyon Yapılmış Veriler İçin %90 Eğitim %10 Test Oranına Göre En İyi Analiz Sonuçları

HİSSE SENEDİ	EĞİTİM FONKSİYONU	GİZLİ KATMAN – NÖRON SAYISI	TOPLAM “R”	MSE
BİST ELEKTRİK	Bayesian Regularization	5-10	0.999	0.0014
AKENR	Bayesian Regularization	5-10	0.99501	0.0032
AKSUE	Bayesian Regularization	5-10	0.99816	0.0054
AYEN	Bayesian Regularization	5-10-15	0.9975	0.0063
ZOREN	Bayesian Regularization	5-10-15	0.99408	0.0039

Tablo 3.26.’da hisse senetlerine ait %90 eğitim %10 test oranı ile logaritması alınarak normalizasyonu yapılmış verilerle yapılan analizlerin en iyi sonuç alınan “Toplam R” ve “MSE” değerleri bulunmaktadır. Bu tabloya göre Bayesian Regularization fonksiyonunun diğerlerine göre daha başarılı olduğu gözlemlenmiştir.

Bütün bu sonuçlara baktığımızda hisse senetlerine ait ham verilerle yapılan analiz sonuçlarının toplam R değerleri 0.97 ve üzeri değerde olurken MSE değerlerinin normalizasyonu yapılmış verilerin analiz sonucunda yer alan MSE değerlerine göre daha

yüksek olduğunu görmekteyiz. Bu sebeple verilerin logaritması alınarak normalizasyonu yapılmış analizler daha başarılı performans göstermektedir. Diğer bir kıyaslama konusu ise hisse senetlerinin her biri için normalizasyonu yapılmış verilerden hangi eğitim ve test oranının daha başarılı olduğudur.

Tablo 3.27. Normalizasyon Yapılmış Veriler İçin %80 Eğitim %20 Test Oranı ve %90 Eğitim %10 Test Oranına Göre En İyi Analiz Sonuçlarının Karşılaştırılması

%80 EĞİTİM %20 TEST

HİSSE SENEDİ	EĞİTİM FONKSİYONU	GİZLİ KATMAN-NÖRON SAYISI	TOPLAM "R"	MSE
BİST ELEKTRİK	Bayesian Regularization	5-10	0.99863	0.0026
AKENR	Bayesian Regularization	5-10	0.99006	0.0063
AKSUE	Bayesian Regularization	5-10-15	0.99643	0.0103
AYEN	Bayesian Regularization	5-10-15	0.99697	0.0077
ZOREN	Bayesian Regularization	5-10-15	0.99426	0.0038


%90 EĞİTİM %10 TEST

HİSSE SENEDİ	EĞİTİM FONKSİYONU	GİZLİ KATMAN-NÖRON SAYISI	TOPLAM "R"	MSE
BİST ELEKTRİK	Bayesian Regularization	5-10	0.999	0.0014
AKENR	Bayesian Regularization	5-10	0.99501	0.0032
AKSUE	Bayesian Regularization	5-10	0.99816	0.0054
AYEN	Bayesian Regularization	5-10-15	0.9975	0.0063
ZOREN	Bayesian Regularization	5-10-15	0.99408	0.0039

Tablo 3.27.'ye bakıldığında çoğunlukla %90 eğitim %10 test oranı ve bütün hisse senetleri için Bayesian Regularization eğitim fonksiyonu ile yapılan analizlerin daha başarılı olduğu görülmektedir. Yalnızca ZOREN Hisse senedinin %80 eğitim %20 test oranıyla diğerine göre daha başarılı olduğu görülmektedir. Ancak ZOREN hisse senedi için, %90 eğitim %10 test oranıyla yapılan analiz ile %80 eğitim %20 test oranıyla yapılan analizin sonucunda çok fazla bir fark olmadığı gözlemlenmiştir. Bunun yanında gizli katman sayısı ve nöron sayısının kaç olması gerektiği ile ilgili kesin bir sonuca varılamamıştır. Fakat tek gizli katman kullanılarak oluşturulan modellerin diğer modellere göre başarısının daha düşük olduğu ifade edilebilir.


XELKT Endeksi için en iyi sonuç %90 Eğitim %10 Test Oranı ile 1. Gizli katmanında 5 nöron 2. Gizli katmanında 10 nöron bulunan 2 gizli katmandan oluşan Bayesian Regularization eğitim fonksiyonudur. XELKT Endeksi'ne ait en iyi sonuca ulaşılan analizin grafikleri aşağıda yer almaktadır.

Şekil 3.1: XELKT Endeksi Yapay Sinir Ağı Yapısı




XELKT Endeksi için Matlab’da oluşturulan sinir ağı modelinde Şekil 3.1.’de görüldüğü üzere 6 girdi değişkeni 1 çıktı değişkeni seçilmiştir. İlk gizli katmanda 5 nöron, ikincisinde 10 nöron bulunan ve ilk gizli katmanda Hiperbolik Tanjant Sigmoid transfer fonksiyonu ikinci gizli katmanda Logaritmik Sigmoid transfer fonksiyonu kullanılmıştır.

Şekil 3.2: XELKT Endeksi Performans Grafiği




Şekil 3.2.'de XELKT Endeksi Performansı Grafiği yer almaktadır. En iyi eğitim performansı değeri 1000. Epoch da 0.0011934 olarak ifade edilmiştir. 1000. Epoch gerçekleştikten sonra eğitim durmuştur.

Şekil 3.3: XELKT Endeksi Hata Histogram Grafiği



Hata histogram grafiği hedeflenen değerler ile analiz sonucunda ulaşılan değerler arasındaki farkın yani hataların dağılımını göstermektedir. Bu nedenle bazı değerler negatiftir. Bu grafikte mavi renkteki sütunlar eğitim verilerini, kırmızı sütunlar ise test verilerini temsil etmektedir. Turuncu çizgi ise sıfır hata noktasını ifade etmektedir. Grafikte hata dağılımının çoğunlukla -0.1071 ve 0.1115 arasında olduğu görülmektedir.


Şekil 3.4: XELKT Endeksi Regresyon Grafiği



Regresyon grafiđi modelin; eđitim verisi, test verisi ve her ikisini de kapsayan, bu alıřmada Toplam R olarak belirtilen veri grupları zerindeki bařarısını lmektedir. Burada dikey eksen ulařılan deđerleri, yatay eksen ise hedeflenen deđerleri ifade etmektedir. Hedeflenen deđer ve ulařılan deđer arasında iyi bir uyum olduđunu syleyebilmek iin diđer renkli izgilerin $Y=T$ ile ifade edilen 45 derecelik kesikli izginin zerinde veya bu izgiye yakın olması gerekir. Aynı zamanda bu durum R ile ifade edilen sayısal deđerin 1 veya 1'e yakın olması demektir. XELKT Endeksi'nin regresyon grafiđine baktıđımızda Eđitim R, Test R ve Toplam R deđerlerinin 0.99'un zerinde olduđu grlmektedir. Bu durum hedeflenen deđer ve ulařılan deđer arasında iyi bir uyum olduđu ve MSE deđer de gz nnde bulundurulduđuunda sinir ađı modelinin bařarılı olduđunu gstermektedir.


AKENR hisse senedi iin en iyi sonu %90 Eđitim %10 Test Oranı ile 1. Gizli katmanında 5 nron 2. Gizli katmanında 10 nron bulunan 2 gizli katmandan oluřan Bayesian Regularization eđitim fonksiyonudur. AKENR hisse senedine ait en iyi sonuca ulařılan analizin grafikleri ařađıda yer almaktadır.

řekil 3.5: AKENR Hisse Senedi Yapay Sinir Ađı Yapısı




AKENR Hisse Senedi iin Matlab'da oluřturulan sinir ađı modelinde řekil 3.5.'de grldđu zere 6 girdi deđerřeni 1 ıktı deđerřeni seilmiřtir. İlk gizli katmanda 5 nron, ikincisinde 10 nron bulunan ve ilk gizli katmanda Hiperbolik Tanjant Sigmoid transfer fonksiyonu ikinci gizli katmanda Logaritmik Sigmoid transfer fonksiyonu kullanılmıřtır.

Şekil 3.6: AKENR Hisse Senedi Performans Grafiği




Şekil 3.6.'ya göre 752. Epoch gerçekleştirildikten sonra eğitim durmuştur. En iyi eğitim performans değeri 751. Epoch da 0.002172 olarak ifade edilmiştir.

Şekil 3.7: AKENR Hisse Senedi Hata Histogram Grafiği




Hata histogram grafiğine göre hataların çoğunluğu -0.1592 ve 0.1252 arasında dağılım göstermektedir.

Şekil 3.8: AKENR Hisse Senedi Regresyon Grafiği



Şekil 3.8: AKENR Hisse Senedi Regresyon Grafiğinde test verisi R değeri 0.96635 olmasına karşın eğitim R değeri ve Toplam R değeri 0.99'un üzerindedir. Bu durum, MSE değeri de göz önünde bulundurulduğunda sinir ağı modelinin başarılı olduğunu göstermektedir.


Şekil 3.9: AKSUE Hisse Senedi Yapay Sinir Ağı Yapısı



AKSUE Hisse Senedi için Matlab'da oluşturulan sinir ağı modelinde Şekil 3.9.'da görüldüğü üzere 6 girdi değişkeni 1 çıktı değişkeni seçilmiştir. İlk gizli katmanda 5 nöron, ikincisinde 10


nöron bulunan ve ilk gizli katmanda Hiperbolik Tanjant Sigmoid transfer fonksiyonu ikinci gizli katmanda Logaritmik Sigmoid transfer fonksiyonu kullanılmıştır.

Şekil 3.10: AKSUE Hisse Senedi Performans Grafiği




Şekil 3.10.'da 777. Epoch gerçekleşikten sonra eğitim durmuştur. En iyi eğitim performans değeri 609. Epoch da 0.0036634 olarak ifade edilmiştir.

Şekil 3.11: AKSUE Hisse Senedi Hata Histogram Grafiği




Şekil 3.11.'de AKSUE Hisse Senedi Hata Histogram Grafiği verilmiştir. Grafiğe göre hataların çoğunluğu -0.1639 ve 0.1758 aralığında dağılım göstermektedir.

Şekil 3.12: AKSUE Hisse Senedi Regresyon Grafiği




AKSUE hisse senedi regresyon grafiğinde eğitim, test ve Toplam R değerlerinin hepsinin de 0.99'un üzerinde olduğu görülmektedir. Bu durum, MSE değeri de göz önünde bulundurulduğunda sinir ağı modelinin başarılı olduğunu göstermektedir.

Şekil 3.13: AYEN Hisse Senedi Yapay Sinir Ağı Yapısı




AYEN Hisse Senedi için Matlab’da oluşturulan sinir ağı modelinde Şekil 3.13.’de görüldüğü üzere 6 girdi değişkeni 1 çıktı değişkeni seçilmiştir. İlk gizli katmanda 5 nöron, ikinci gizli katmanda 10 nöron, üçüncü gizli katmanda 15 nöron bulunan ve ilk gizli katmanda Hiperbolik Tanjant Sigmoid transfer fonksiyonu ikinci gizli katmanda Logaritmik Sigmoid transfer fonksiyonu ve üçüncü gizli katmanda Doğrusal fonksiyon kullanılmıştır.

Şekil 3.14: AYEN Hisse Senedi Performans Grafiği




Şekil 3.14.’de 1000. Epoch gerçekleştirildikten sonra eğitim durmuştur. En iyi eğitim performans değeri 1000. Epoch da 0.0036657 olarak ifade edilmiştir.

Şekil 3.15: AYEN Hisse Senedi Hata Histogram Grafiği




AYEN Hisse Senedi Hata histogram grafiğine göre hataların çoğunluğu -0.2251 ve 0.2079 arasında dağılım göstermektedir.

Şekil 3.16: AYEN Hisse Senedi Regresyon Grafiği




AYEN hisse senedi regresyon grafiğinde test R değerinin 0.98731 olduğu görülmektedir. Eğitim ve Toplam R değerlerinin 0.99'un üzerinde olduğu görülmektedir. Bu durum, MSE değeri de göz önünde bulundurulduğunda sinir ağı modelinin başarılı olduğunu göstermektedir.

Şekil 3.17: ZOREN Hisse Senedi Yapay Sinir Ağı Yapısı




ZOREN Hisse Senedi için Matlab’da oluşturulan sinir ağı modelinde Şekil 3.17.’de görüldüğü üzere 6 girdi değişkeni 1 çıktı değişkeni seçilmiştir. İlk gizli katmanda 5 nöron, ikinci gizli katmanda 10 nöron, üçüncü gizli katmanda 15 nöron bulunan ve ilk gizli katmanda Hiperbolik Tanjant Sigmoid transfer fonksiyonu ikinci gizli katmanda Logaritmik Sigmoid transfer fonksiyonu ve üçüncü gizli katmanda Doğrusal fonksiyon kullanılmıştır.

Şekil 3.18: ZOREN Hisse Senedi Performans Grafiği




Şekil 3.18.'de 1000. Epoch gerçekleştirildikten sonra eğitim durmuştur. En iyi eğitim performans değeri 1000. Epoch da 0.0020493 olarak ifade edilmiştir.

Şekil 3.19: ZOREN Hisse Senedi Hata Histogram Grafiği



ZOREN Hisse Senedi Hata histogram grafiğinde göre eğitim ve test verilerinin olduğu sütunlar için hataların çoğunluğu -0.113 ve 0.1304 arasında dağılım göstermektedir.

Şekil 3.20: ZOREN Hisse Senedi Regresyon Grafiği



ZOREN hisse senedi regresyon grafiğinde test R değerinin 0.98262 olduğu görülmektedir. Eğitim ve Toplam R değerlerinin 0.99'un üzerinde olduğu görülmektedir. Bu durum, MSE değeri de göz önünde bulundurulduğunda sinir ağı modelinin başarılı olduğunu göstermektedir.

3.5. Genel Değerlendirme

Literatürde BİST Elektrik Endeksi ile ilgili yapılan çeşitli çalışmalar bulunmaktadır. Bunlardan biri Gürlevik ve Gazel (2020) tarafından hazırlanan; enerji fiyatlarındaki değişimin BİST Elektrik Endeksi fiyatlarına etkisini araştıran bir makaledir. Çalışmada elektrik fiyatları, gaz fiyatları ve brent petrol fiyatları bağımsız değişken, BİST Elektrik Endeksi bağımlı değişken olarak belirlenmiştir. Analiz yöntemi olarak NARDL Doğrusal Olmayan Gecikmesi Dağıtılmış Ototregresif Model kullanmışlardır. Yazarlar Mart 2010- Mart 2019 dönemine ait veriler yardımıyla, bağımsız değişkenler arasındaki ilişkiyi kısa ve uzun vadede NARDL modeli ile incelemişlerdir. NARDL testi sonucunda uzun dönemde BİST Elektrik Endeksi ve gaz fiyatları arasında negatif yönlü ve anlamlı bir ilişki bulunmuş olup BİST Elektrik Endeksi ile brent petrol ve elektrik fiyatları arasında uzun dönem için anlamlı bir ilişki bulunamadığı ifade edilmiştir. Hata düzeltme modeli sonuçlarına göre neredeyse bütün bağımsız değişkenler ile BİST Elektrik Endeksi arasında ilişki bulunduğu belirtilmiştir. Son olarak kısa dönemde BİST Elektrik Endeksi ile elektrik fiyatlarının pozitif bileşenleri EL^+ ve brent petrol

arasındaki ilişkinin pozitif yönlü olduğu açıklanırken, yine kısa dönemde BİST Elektrik Endeksi ile elektrik fiyatlarının negatif bileşenleri EL^- ve gaz fiyatlarının ilişkisinin gecikmelere bağlı olarak pozitif veya negatif olabileceği ifade edilmiştir.

Gümüş ve Kurt Cihangir (2022), USD/TRY Dolar kuru, dünya petrol, doğalgaz, kömür ve BİST100 getirisinin piyasa faiz oranına göre düzeltilmiş ve düzeltilmemiş BİST Elektrik Endeksi getirisine etkisini ölçmek amacıyla değişkenler arasındaki nedensellik ilişkisi için Granger Nedensellik Testi yapmışlar; oynaklık yayılımı içinde farklı yöntemleri kullanmışlardır. Araştırma sonucunda dünya petrol ve kömür fiyatlarındaki değişim ile BİST100 endeksi getirisinin BİST Elektrik Endeksinin piyasa faiz oranına göre düzeltilmiş veriler kullanılarak yapılan analiz için oynaklık yayılma etkisinin bulunurken, dünya doğalgaz fiyatlarındaki değişimin nedensellik ve oynaklık yayılımı yönünden BİST Elektrik Endeksine herhangi bir etki bulunamadığı ifade edilmiştir. Çalışmada, 2010-2020 yılları arasındaki veriler kullanılarak Granger Nedensellik Testi yapılmıştır.

Göker vd. (2024), Rusya- Ukrayna savaşının BİST Elektrik Endeksi'ndeki hisse senetleri getirilerine etkisini incelemişlerdir. Rusya'nın askeri harekâtı başlattığı gün BİST Elektrik Endeksi'nde bulunan şirketlerin ortalama anormal getirilerinin %-5,1 düzeyinde negatif ve istatistiksel olarak anlamlı olduğu, analize dahil edilmiş olan 24 firmanın 22 tanesi olay günü negatif getiri sağladığı belirtilmiştir. BİST Elektrik Endeksi'ndeki negatif getirinin yatırımcıların panik satışından olabileceği gibi enerji sektörüne yapılan yatırımları savaştan daha az etkileneceği düşünülen piyasalara yönlendirmeleri veya bu sektördeki belirsizlikten dolayı başka sektöre yönlendirmelerinden olabileceği yazarlar tarafından açıklanmıştır.

Korkmaz ve Güngör (2018), araştırmalarında küresel ekonomi politika belirsizliğinin BİST İstanbul'da yer alan hisse senedi getirileri üzerindeki etkisi GARCH (1,1) modeli ile analiz etmişlerdir. BİST Elektrik, BİST Kimya, Petrol, Plastik ve BİST Metal Ana Getiri Endeksi serileri için GARCH (1,1) analizinin sonuçlarına göre küresel ekonomi politika belirsizliğindeki artış ilgili sektörlerde yer alan şirketlerin hisse senetlerinin getirilerini azalttığı, ayrıca küresel ekonomi politika belirsizliğinin ilgili sektörlerdeki hisse senetleri getirilerinde oynaklığı artıran etkisinin varyans denklemi incelendiğinde görüldüğü belirtilmiştir.

Ismayılov ve Kiren Gürler (2022), araştırmalarında CDS, petrol fiyatları ve döviz kurlarının BİST Elektrik Endeksi'ne etkisini araştırmışlardır. 2008- 2022 yılları için aylık veriler kullanılarak yapılan analiz sonucunda uzun dönemde brent petrol fiyatlarının ve CDS

değerinin BİST Elektrik Endeksi üzerinde ters bir etkisi olduğu belirtilmiştir. Yazar, brent petrol fiyatında oluşan bir artışın hisse senedi fiyatlarını %21 oranında düşürdüğünü ifade etmiştir. Döviz kurları ve hisse senedi fiyatları arasında uzun dönemde pozitif bir etki bulunmuştur. Hata düzetme modeli ile kısa dönemde BİST Elektrik Endeksi ve CDS arasında negatif etkiden söz edilirken, brent petrol ve BİST Elektrik Endeksi arasında pozitif bir ilişki olduğu, BİST Elektrik Endeksi ve döviz kuru arasında kısa dönemde anlamlı ilişkiler bulunamadığı açıklanmıştır.

Bu araştırmada BİST Elektrik Endeksi ve bu endeks içindeki dört hisse senedi için fiyat tahmini yapılmıştır. Çalışma, 2004-2024 dönemlerini kapsayan 20 yıllık veriler ile yapılmıştır. Araştırmada ham verilere göre yapılan analizde toplam R değerleri iyi olmasına karşın MSE değerleri, normalizasyonu yapılmış verilere nazaran daha yüksek çıkmıştır. Çalışma sonucunda normalizasyonu yapılmış verilerin ham verilere göre daha başarılı sonuçlara ulaştığı gözlemlenmiş olup normalizasyonu yapılmış verilerle yapılan, özellikle %90 eğitim ve %10 test oranına göre belirlenmiş analizlerin çoğunlukla MSE değerlerinin daha düşük, Toplam R değerlerinin daha yüksek olduğu görülmektedir.

SONUÇ

Enerji tüketim artışı, ülkelerin gelişmişlik göstergelerinden biridir. Teknolojik gelişmelerin ayrılmaz bir parçası haline gelen enerjinin tüketimindeki artış, enerji kaynaklarının önemini artırmaktadır. Elektrik enerjisi ise bu durumdan en çok etkilenen alanlardan biri haline gelmiştir. Ülkeler açısından yenilenebilir enerjinin önemi artmıştır. Bu sebeple güneş enerjisi santralleri ve rüzgâr enerjisi santralleri gibi yenilenebilir enerji kaynaklarından elektrik üretimi popüler bir duruma gelmiştir. Bu durum hem güneş enerjisi santralleri, rüzgâr enerjisi santralleri gibi elektrik üretim tesislerine yatırım yapan yatırımcıların hem de bu işle ilgilenen şirketlerin borsadaki hisse senetlerine yatırım yapan yatırımcıların ilgisini çekmektedir. Yatırımcıların çeşitli analiz ve yöntemler ile yaptıkları yatırımların getirisini tahmin edebilmeleri ise kâr- zarar açısından bilgilenmeleri ve buna göre yatırım yapıp yapmamaları açısından ciddi bir avantaj oluşturmaktadır. Literatürdeki ulaşılabilen araştırmalara bakıldığında yapay sinir ağları ile hisse senedi fiyat tahmini konusunda birçok araştırmalar bulunurken yine literatürden ulaşılabildiği kadarıyla yapay sinir ağları ile bu bağımsız değişkenlerle ve bu şekilde farklı yapay sinir ağları modelleriyle yapılmış BİST Elektrik Endeksi fiyat tahmini ile ilgili bir çalışmayla karşılaşılmamış olması çalışmayı özgün kılan nedenler olarak açıklanabilir.

Çalışmada Dolar, Euro, Gram Altın, Brent Petrol, TÜFE ve BİST 100 Endeksi verilerinin BİST Elektrik Endeksi ve bu endeks içinde yer alan AKENR, AKSUE, AYEN ve ZOREN hisse senetlerinin fiyat tahminindeki etkisi incelenmiştir. Bunun için Yapay Sinir Ağları Yöntemi kullanılmıştır. Microsoft Office Excel ve MATLAB programları yardımıyla analiz yapılmıştır. Dolar, Euro, Gram Altın, Brent Petrol, TÜFE ve BİST 100 Endeksi verileri bağımsız değişkenler; AKENR, AKSUE, AYEN, ZOREN ve BİST Elektrik verileri ise bağımlı değişkenler olmak üzere ayrı ayrı 5 yapay sinir ağı modeli olacak şekilde çalışma yapılmıştır. Çalışmada toplamda 180 analiz yapılmıştır. Araştırmada ham veri ve normalizasyonu yapılmış veriler, seçilen eğitim ve test oranı, eğitim fonksiyonu, gizli katman ve bu katmanlardaki nöron sayıları değiştirilerek birçok model oluşturulmuştur. Amaç, bu modellerden hangisi veya hangilerinin belirlenen performans ölçütleri açısından daha iyi olabileceğini belirlemek olmuştur. Çalışmada YSA modellerinin performans ölçütleri Toplam

R değeri ve MSE değeri olarak belirlenmiştir. Sonuçta normalizasyonu yapılmış verilerin analizde daha başarılı performans gösterdiği belirlenmiş ve normalizasyonu yapılmış veriler için %90 eğitim %10 test oranı kullanılarak Bayesian Regularization eğitim fonksiyonu ile çok katmanlı YSA modeli oluşturularak daha başarılı sonuçlar elde ettiği gözlemlenmiştir. Eğitim fonksiyonları içerisinde Scaled Conjugate Gradient eğitim fonksiyonu diğerlerine göre daha az başarılı olmuştur. Çınaroğlu ve Avcı (2020) çalışmalarında LM ve BR eğitim fonksiyonlarını karşılaştırmış ve BR eğitim fonksiyonunun daha başarılı olduğunu belirtmişlerdir. Yıldız (2006)'da yaptığı çalışmada döviz kuru tahmini için içerisinde Levenberg- Marquardt (LM), Bayesian Regularization (BR) ve Ölçekli Eşlenik Gradyan (SCG) bulunan 12 farklı eğitim algoritmasından Bayesian Regularization fonksiyonunun başarılı olduğunu ifade etmiştir. Bu çalışmada, oluşturulan modellerin performans ölçütü MSE değeri dikkate alındığında Bayesian Regularization eğitim fonksiyonun diğerlerine göre daha iyi sonuçlara ulaştığı görülmektedir.

İlerideki çalışmalarda faiz oranı, para arzı, sanayi üretim endeksi veya üretici fiyat endeksi verileri ya da firmaların fiyat/ kazanç oranı, piyasa değeri/ defter değeri oranı, özsermaye kârlılığı gibi verileri de analiz değişkenlerine eklenerek BİST Elektrik Endeksi fiyat tahmini yapılabilir. Yine farklı endeksler için bu bağımsız değişkenler ve yapay sinir ağı modelleri kullanılarak fiyat öngörüsü yapılabilir. Aynı zamanda değişkenlere ait verilerin bulunabilmesi durumunda 20 yıldan daha uzun dönemler için yöntemin başarısı incelenebilir. Bunun yanında farklı YSA modellerinde veya modeli etkileyen parametrelerde de değişiklikler yapılarak farklı çalışmalar literatüre sunulabilir.

KAYNAKÇA

- Akagün, H. Y. (2006). Finansal varlıkları fiyatlama modeli (FVFM) ve NewYork borsası (NYSE)'de uygulanması (Yüksek Lisans Tezi). İstanbul Üniversitesi Sosyal Bilimler Enstitüsü.
- Akcan, A., & Kartal, C. (2011). İMKB sigorta endeksini oluşturan şirketlerin hisse senedi fiyatlarının yapay sinir ağları ile tahmini. *Muhasebe ve Finansman Dergisi*, (51), 27-40.
- Akel, V., & Bayramoğlu, M. F. (2008). Kriz Dönemlerinde Yapay Sinir Ağları ile Finansal Öngöründe Bulunma: İMKB 100 Endeksi Örneği. Uluslararası Sermaye Hareketleri ve Gelişmekte Olan Piyasalar Uluslararası Sempozyumu (ss. 79-87). 24-27 Nisan, Balıkesir.
- 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.
- Aksoy, A., & Tanrıöven, C. (2014). *Sermaye piyasası yatırım araçları ve analizi* (5. Baskı). Detay Yayıncılık.
- Aksoy, M., & Topcu, N. (2013). Altın ile hisse senedi ve enflasyon arasındaki ilişki. *Atatürk Üniversitesi İktisadi ve İdari Bilimler Dergisi*, 27(1), 59-78.
- Aktaş, R., Doğanay, M. M., Gökmen, Y., & Somuncu, K. (2017). *Finansal yönetim*. Beta Basım Yayım Dağıtım.
- Alekberov, E. (2001). Finansal varlık fiyatlama modeli'nin İMKB'de test edilmesi (Yüksek Lisans Tezi). İstanbul Üniversitesi Sosyal Bilimler Enstitüsü.
- Altan, Ş. (2008). Döviz kuru öngörü performansı için alternatif bir yaklaşım: yapay sinir ağı. *Gazi Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 10(2). 141-160.
- Asilkan, Ö., & Irmak, S. (2009). İkinci el otomobillerin gelecekteki fiyatlarının yapay sinir ağları ile tahmin edilmesi. *Süleyman Demirel Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 14(2), 375-391.
- Aydın, Ö. F. (2019). Yapay sinir ağları ile enflasyon tahmini (Yüksek Lisans Tezi). Beykent Üniversitesi Fen Bilimleri Enstitüsü.

- Bahadır, İ. (2008). Bayes teoremi ve yapay sinir ağları modelleriyle borsa gelecek değer tahmini uygulaması (Yüksek Lisans Tezi). TOBB Ekonomi ve Teknoloji Üniversitesi Fen Bilimleri Enstitüsü.
- Bayır, F., (2006). Yapay sinir ağları ve tahmin modellemesi üzerine bir uygulama (Yüksek Lisans Tezi). İstanbul Üniversitesi Sosyal Bilimler Enstitüsü.
- Bodie, Z., Kane, A., & Marcus, A. J. (2018). Yatırımların temelleri (Çev. S. Demir). Nobel Akademik Yayıncılık.
- Chen, A. S., Leung, M. T., & Daouk, H. (2003). Application of neural networks to an emerging financial market: forecasting and trading the Taiwan Stock Index. *Computers & Operations Research*, 30. 901-923.
- Çakar, R., & Özkan, O. (2020). Riski seven ve riskten kaçan yatırımcıların optimum portföy seçimi yapabilecekleri piyasalar. *Anadolu Üniversitesi Sosyal Bilimler Dergisi*, 20(1), 23-38. <https://doi.org/10.18037/ausbd.700324>
- Çalışkan, M. M. T., & Deniz, D. (2015). Yapay sinir ağlarıyla hisse senedi fiyatları ve yönlerinin tahmini. *Eskişehir Osmangazi Üniversitesi İİBF Dergisi*, 10(3), 177-194.
- Çanakcı, A. (2006). Yapay sinir ağlarının makroekonomik bir model üzerine uygulanması: bir Türkiye örneği (Yüksek Lisans Tezi). Gazi Üniversitesi Sosyal Bilimler Enstitüsü.
- Çınaroğlu, E., & Avcı, T. (2020). THY hisse senedi değerinin yapay sinir ağları ile kestirimi. *Atatürk Üniversitesi İktisadi ve İdari Bilimler Dergisi* 34(1). 1-19. <https://doi.org/10.16951/atauniiibd.530322>
- Dayı, F. (2017). Birden fazla borsada işlem gören hisse senetlerinin değerlendirilmesi (Doktora Tezi). Gazi Üniversitesi Sosyal Bilimler Enstitüsü.
- Dayı, F. (2020). Sistemik riskin hisse senedi getirisine etkisi: Borsa İstanbul örneği. *Optimum Ekonomi ve Yönetim Bilimleri Dergisi*. 7(1), 1-20. <https://doi.org/10.17541/optimum.510368>
- Demirel, A. C., & Hazar, A. (2021). Borsa endekslerinin birbirleriyle etkileşimi ve endeks yönünün tahmini: BİST100 üzerine bir uygulama. *Ekonomi ve Finansal Araştırmalar Dergisi*, 3(1), 1-8.

- Dörtbölük, G. (2019). Piyasa değeri/ defter değeri yöntemine göre hisse senedi değerlendirme, BİST çimento sektörü üzerine bir uygulama (Yüksek Lisans Tezi). Marmara Üniversitesi Sosyal Bilimler Enstitüsü.
- Dramalija, N. (2008). Hisse senetleri çeşitlendirilmesi ve risk-getiri analizine uygulamalı bir yaklaşım (Yüksek Lisans Tezi). Dokuz Eylül Üniversitesi Sosyal Bilimler Enstitüsü.
- Elmas, Ç. (2021). *Yapay zeka uygulamaları* (5. Baskı). Seçkin Yayıncılık.
- Enerji ve Tabii Kaynaklar Bakanlığı, <https://enerji.gov.tr/bilgi-merkezi-enerji-elektrik> (Erişim Tarihi: 9.07.2024).
- Göker, İ. E. K., Aktümsek, E., & Eren, B. S. (2024). Rusya-Ukrayna savaşının hisse senedi getirileri üzerindeki etkisi: BIST elektrik endeksi üzerine bir uygulama. *Hitit Sosyal Bilimler Dergisi*, 17 (ICAFR23 Özel Sayısı), 159-171. <https://doi.org/10.17218/hititsbd.1375490>
- Gümüş, T., & Kurt Cihangir, Ç. (2022). Dünya petrol, kömür ve doğal gaz fiyatları ile BİST elektrik endeksi arasındaki nedensellik ilişkisi ve oynaklık yayılımı. *Alanya Akademik Bakış*, 6(1), 1587-1603. <https://doi.org/10.29023/alanyaakademik.887155>
- Gür, N. (2009). Hisse senedi fiyat hareketlerinin tahmini için bir yapay sinir ağı modeli önerisi (Yüksek Lisans Tezi). Kocaeli Üniversitesi Fen Bilimleri Enstitüsü.
- Gürlevik, F., & Gazel, S. (2020). Enerji fiyatlarındaki değişimin hisse senedi fiyatlarına etkisi: BİST elektrik endeksi üzerine bir uygulama. *EKEV Akademi Dergisi*, (82), 119-138.
- Hamzaçebi, C. (2005). Geleceği tahminde yapay sinir ağları için sezgisel öğrenme algoritması (Doktora Tezi). Gazi Üniversitesi Fen Bilimleri Enstitüsü.
- Hamzaçebi, C. (2021). *Matlab uygulamalı yapay sinir ağları* (2. Baskı). Seçkin Yayıncılık.
- Haykin, S. (2009). *Neural networks and learning machines* (Third Edition). Pearson Prentice Hall.
- Ismayilov, J., & Kiren Gürler, Ö. (2022). Kredi temerrüt takasları, petrol fiyatları ve döviz kurlarının Türkiye'nin enerji sektörüne etkisi: BİST elektrik endeksi örneği. *Journal of Management and Economics Research*, 20(3), 405-419. <https://doi.org/10.11611/yead.1168027>

- Kaastr, I., & Boyd, M. (1996). Designing a neural network for forecasting financial and economic time series, *Neurocomputing*, 10. 215-236.
- Kalfa, V. R. (2010). Portföy analizi ve doğrusal programlama metodu ile İMKB’de bir uygulama (Yüksek Lisans Tezi). Adnan Menderes Üniversitesi Sosyal Bilimler Enstitüsü.
- Kanas, A., & Yannopoulos, A. (2001). Comparing linear and nonlinear forecasts for stock returns. *International Review of Economics and Finance*, 10. 383-398.
- Karacameydan, F. (2009). Yatırım fonları net varlık değerlerinin yapay sinir ağırları yöntemiyle tahmin edilmesi (Yüksek Lisans Tezi). Bozok Üniversitesi Sosyal Bilimler Enstitüsü.
- Karakul, A. K. (2020). Yapay sinir ağırları ile BIST-100 endeks değerinin tahmin edilmesi. *Mehmet Akif Ersoy Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 7(2), 497-509. <https://doi.org/10.30798/makuiibf.721866>
- Karan, M. B. (2018). *Yatırım analizi ve portföy yönetimi* (5. Baskı). Gazi Kitabevi.
- Kayahan, C. (2019). Başabaş Analizi ve Kaldıraçlar. İçinde F. Kaya (Ed.), *Finansal yönetim* (ss. 141-157). Beta Basım Yayım Dağıtım.
- Kendirli, S., & Çankaya, M. (2016). Ham petrol fiyatlarının BİST 100 ve BİST ulaştırma endeksleri ile ilişkisi. *Kastamonu Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 12(2), 136-141.
- Kim, T. Y., Oh, K. J., Sohn, I., & Hwang, C. (2004). Usefulness of artificial neural networks for early warning system of economic crisis. *Expert Systems with Applications*, 26. 583-590.
- Koç Ustalı, N., Tosun, N., & Tosun, Ö. (2021). Makine öğrenmesi teknikleri ile hisse senedi fiyat tahmini. *Eskişehir Osmangazi Üniversitesi İİBF Dergisi*, 16(1), 1-16. <https://doi.org/10.17153/oguiibf.636017>
- Korkmaz, Ö., & Güngör, S. (2018). Küresel ekonomi politika belirsizliğinin Borsa İstanbul’da işlem gören seçilmiş endeks getirileri üzerindeki etkisi. *Anemon Muş Alparslan Üniversitesi Sosyal Bilimler Dergisi*, 6(ICEESS’18), 211-219. <https://doi.org/10.18506/anemon.452749>

- Korkmaz, T., & Ceylan, A. (2017). *Sermaye piyasası ve menkul değer analizi* (8. Baskı). Ekin Yayınevi.
- Korkmaz, T., (2013). Portföy Yönetimi. İçinde M. Başar (Ed)., *Portföy yönetimi* (ss. 2-34). T.C. Anadolu Üniversitesi Yayını No: 2852. Açıköğretim Fakültesi Yayını No: 1809.
- Korkut, D. (2019). Yapay sinir ağları yöntemi ile talep tahmini ve ayakkabı sektörüne uygulaması (Yüksek Lisans Tezi). Ankara Hacı Bayram Veli Üniversitesi Lisansüstü Eğitim Enstitüsü.
- Kuzu, S. (2017). Petrol fiyatları ve bazı makro ekonomik değişkenlerin Borsa İstanbul'da yer alan bir takım endeksler üzerindeki etkisinin araştırılması. *Yönetim ve Ekonomi Dergisi*, 24(2), 579-599. <https://doi.org/10.18657/yonveek.299334>
- Metin, S. (2017). Büyüme ve değer paylarından oluşan portföylerin performans ölçümleri: BİST'de bir uygulama (Yüksek Lisans Tezi). Mersin Üniversitesi Sosyal Bilimler Enstitüsü.
- Mucuk, İ. (2014). *Modern işletmecilik* (19. Basım). Türkmen Kitabevi.
- Okka, O. (2015). *Analitik finansal yönetim teori ve problemler* (2. Basım). Nobel Akademik Yayıncılık.
- Özalp, A., & Anagün, A. S. (2003). Yapay sinir ağı performansına etki eden faktörlerin analizinde taguchi yöntemi: hisse senedi fiyat tahmini uygulaması. *İstatistik Araştırma Dergisi*, 2(1), 29-45.
- Özcan Akdağ, N., Karaatlı, M., & Kocabıyık, T. (2022). BIST ulaştırma endeksinin YSA NARX modeli ile öngörülmesi. *Alanya Akademik Bakış*, 6(3), 2721-2746. <https://doi.org/10.29023/alanyaakademik.1088404>
- Özçalıcı, M. (2016). Yapay sinir ağları ile çok aşamalı fiyat tahmini: BIST30 senetleri üzerine bir araştırma. *Dokuz Eylül Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 31(2), 209-227. <https://doi.org/10.24988/deuiibf.2016312517>
- Özer, A., Kaya, A., & Özer, N. (2011). Hisse senedi fiyatları ile makroekonomik değişkenlerin etkileşimi. *Dokuz Eylül Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 26(1), 163-182.
- Öztürk, K., & Şahin, M. E. (2018). Yapay sinir ağları ve yapay zekâ'ya genel bir bakış. *Takvim-i Vekayi*, 6(2), 25-36.

- Sail, G. (2021). Yapay sinir ağırları yöntemiyle pay senedi fiyatlarının tahmini ve bu tahminler üzerinde davranışsal finans yaklaşımlarının test edilmesi (Doktora Tezi). Beykent Üniversitesi Lisansüstü Eğitim Enstitüsü.
- Saleck, C. (2018). Yatırım fonları risk ve getiri analizi: Türkiye üzerine bir uygulama (Yüksek Lisans Tezi). Dokuz Eylül Üniversitesi Sosyal Bilimler Enstitüsü.
- Sarı, S. S., & Saka Ilgın, K. (2022). BIST-100 endeks hareketlerinin BRICS endeksleri aracılığıyla tahmin edilmesi: yapay sinir ağırları uygulaması. *Abant Sosyal Bilimler Dergisi*, 22(1), 350-366. <https://doi.org/10.11616/asbi.1096346>
- Sarıkaya, G. (2019). Yapay sinir ağırları ve regresyon modelleri ile Bist Ulusal-100 endeksinin tahmini. *21. Yüzyılda Eğitim ve Toplum*, 8(23), 325-340.
- Sarılı, S. (2014). Finansal varlık fiyatlama modellerinin zaman serisi ve panel veriyle analizi: Türkiye’de banka hisse senetleri üzerine uygulama (Doktora Tezi). Marmara Üniversitesi Bankacılık ve Sigortacılık Enstitüsü.
- Sevinçtekin, E. (2014). İmalat sektöründe yapay sinir ağırları uygulaması (Yüksek Lisans Tezi). Yıldız Teknik Üniversitesi Fen Bilimleri Enstitüsü.
- Şahin, E. E., & Özkan, O. (2018). Kredi temerrüt takası, döviz kuru ve BİST100 endeksi ilişkisi. *Hitit Üniversitesi Sosyal Bilimler Enstitüsü Dergisi*, 11(3), 1939-1945. <https://doi.org/10.17218/hititsosbil.450178>
- Şentürk, S. (1997). İMKB bileşik endeksi ve hisse senetleri fiyatları arasındaki ilişkinin ekonometrik analizi (Yüksek Lisans Tezi). İstanbul Üniversitesi Sosyal Bilimler Enstitüsü.
- TDK (Türk Dil Kurumu). (2020). Türk Dil Kurumu Sözlükleri. <https://sozluk.gov.tr/> (Erişim Tarihi: 01.12.2020).
- TDK (Türk Dil Kurumu). (2024). Türk Dil Kurumu Sözlükleri. <https://sozluk.gov.tr/> (Erişim Tarihi: 15.02.2024).
- Tektaş, A., & Karataş, A. (2004). Yapay sinir ağırları ve finans alanına uygulanması: hisse senedi fiyat tahminlemesi. *Atatürk Üniversitesi İktisadi ve İdari Bilimler Dergisi*, 18(3-4), 337-349.

- Toraman, C. (2008). Demir-elik sektrnde yapay sinir ađları ile hisse senedi fiyat tahmini: Erdemir A.Ş. ve Kardemir A.Ş. zerine bir tahmin uygulaması. *Muhasebe ve Finansman Dergisi* (39). 44-57.
- TİİK (Trkiye İstatistik Kurumu). (2020). <https://data.tuik.gov.tr> (Eriřim Tarihi:16.09.2020).
- TİİK (Trkiye İstatistik Kurumu). (2024). <https://data.tuik.gov.tr> (Eriřim Tarihi:26.04.2024).
- nl, M. (2023). Makroekonomik gstergeler ve BİST enerji endeksi arasındaki iliřkinin incelenmesi: ampirik bir analiz. *Karamanođlu Mehmetbey niversitesi Sosyal ve Ekonomik Arařtırmalar Dergisi*, 25(45), 984-997.
- Vural, B. B. (2007). Yapay sinir ađları ile finansal tahmin (Yksek Lisans Tezi). Ankara niversitesi Sosyal Bilimler Enstits.
- Yanık, E. (2019). İř makineleri sektrnde yapay sinir ađları ile talep tahmini uygulaması (Yksek Lisans Tezi). Kırıkkale niversitesi Fen Bilimleri Enstits.
- Yarar, A. (2004). Beyřehir gl su seviyesi deđiřimlerinin yapay sinir ađları ile belirlenmesi (Yksek Lisans Tezi). Seluk niversitesi Fen Bilimleri Enstits.
- Yavuz, M., Sakarya, ř., & zdemir, N. (2015). Yapay sinir ađları ile risk-getiri tahmini ve portfy analizi. *Niđde niversitesi İktisadi ve İdari Bilimler Fakltesi Dergisi*, 8(4), 87-107.
- Yavuz, S. (2006). Performans artırmaya ynelik paralel mimarilerin yapay sinir ađları yaklařımı ile deđerlendirilmesi (Doktora Tezi). Yıldız Teknik niversitesi Fen Bilimleri Enstits.
- Yıldırım, K., řıklar, İ., Bakırtař, İ., Koyuncu, C., Yılmaz, R., & Erdiņ, Z. (2013). Toplam Harcama ve Milli Hasıla Dzeyinin Belirlenmesi (Basit Keynesyen Model). İinde K. Yıldırım (Ed.), *İktisada giriř* (ss. 373-406). Pelikan Yayıncılık.
- Yıldırım, M. (2019). Getiri, Risk ve Risk Trleri. İinde F. Kaya (Ed.), *Finansal ynetim* (ss. 411-426). Beta Basım Yayım Dađıtım.
- Yıldız, . (2006). Dviz kuru tahmininde yapay sinir ađlarının kullanımı (Yksek Lisans Tezi). Eskiřehir Osmangazi niversitesi Sosyal Bilimler Enstits.
- Yiđiter, ř. Y., Sarı, S. S., & Bařakın, E. E. (2017). Hisse senedi kapanıř fiyatlarının yapay sinir ađları ve bulanık mantık ıkarım sistemleri ile tahmin edilmesi. *Kahramanmarař St İmam niversitesi İktisadi ve İdari Bilimler Fakltesi Dergisi*, 7(1), 1-22.

- Yurtoğlu, H. (2005). Yapay sinir ağları metodolojisi ile öngörü modellemesi: bazı makroekonomik değişkenler için Türkiye örneği (Uzmanlık Tezi), Devlet Planlama Teşkilatı. DPT Yayın No:2683.
- Yüksel, R. (2014). Altın fiyatlarının yapay sinir ağları ile tahmini ve bir uygulama (Yüksek Lisans Tezi). Dumlupınar Üniversitesi Sosyal Bilimler Enstitüsü.
- Yüksel, R., & Akkoç, S. (2016). Altın fiyatlarının yapay sinir ağları ile tahmini ve bir uygulama. *Doğuş Üniversitesi Dergisi*, 17(1). 39-50.
- Zengin, E. (2006). Hisse senedi portföylerinin yönetiminde pratik yaklaşımlar ve İMKB uygulaması (Yüksek Lisans Tezi). Dokuz Eylül Üniversitesi Sosyal Bilimler Enstitüsü.
- Zhang, G., Patuwo, B. E., & Hu, M. Y. (1998). Forecasting with artificial neural networks: The state of the art, *International Journal of Forecasting*, 14. 35–62.

EKLER

EK 1. %80 EĞİTİM %20 TEST ORANI ve Levenberg-Marquardt Eğitim Fonksiyonu ile 1 Gizli Katman ve Gizli katmanda 5 Nöron bulunan Yapay Sinir Ağı Modeline ait oluşturulan MATLAB Kodları

```
x=input;
t=target;
trainFcn='trainlm';
hiddenLayerSize=[5];
net=feedforwardnet(hiddenLayerSize,trainFcn);
net.layers{1}.transferFcn='tansig';
net.divideParam.trainRatio=80/100;
net.divideParam.testRatio=20/100;
net.performFcn='mse';
netplotFcn={'plotperform','plottrainstate','ploterrhist','plotregression'};
[net,tr]=train(net,x,t);
view(net);
output=net(x);
error=gsubtract(t,output);
performance=perform(net,t,output);
tInd=tr.testInd;
tstOutputs=net(x(:,tInd));
tstPerform=perform(net,t(tInd),tstOutputs);
```

EK 2. %80 EĞİTİM %20 TEST ORANI ve Levenberg-Marquardt Eğitim Fonksiyonu ile 2 Gizli Katman ve Gizli katmanlarda 5-10 Nöron bulunan Yapay Sinir Ağı Modeline ait oluşturulan MATLAB Kodları

```
x=input;

t=target;

trainFcn='trainlm';

hiddenLayerSize=[5 10];

net=feedforwardnet(hiddenLayerSize,trainFcn);

net.layers{1}.transferFcn='tansig';

net.layers{2}.transferFcn='logsig';

net.divideParam.trainRatio=80/100;

net.divideParam.testRatio=20/100;

net.performFcn='mse';

netplotFcn={'plotperform','plottrainstate','ploterrhist','plotregression'};

[net,tr]=train(net,x,t);

view(net);

output=net(x);

error=gsubtract(t,output);

performance=perform(net,t,output);

tInd=tr.testInd;

tstOutputs=net(x(:,tInd));

tstPerform=perform(net,t(tInd),tstOutputs);
```

**EK 3. %80 EĞİTİM %20 TEST ORANI ve Levenberg-Marquardt Eğitim Fonksiyonu
ile 3 Gizli Katman ve Gizli katmanlarda 5-10-15 Nöron bulunan Yapay Sinir Ağı
Modeline ait oluşturulan MATLAB Kodları**

```
x=input;

t=target;

trainFcn='trainlm';

hiddenLayerSize=[5 10 15];

net=feedforwardnet(hiddenLayerSize,trainFcn);

net.layers{1}.transferFcn='tansig';

net.layers{2}.transferFcn='logsig';

net.layers{3}.transferFcn='purelin';

net.divideParam.trainRatio=80/100;

net.divideParam.testRatio=20/100;

net.performFcn='mse';

netplotFcn={'plotperform','plottrainstate','ploterrhist','plotregression'};

[net,tr]=train(net,x,t);

view(net);

output=net(x);

error=gsubtract(t,output);

performance=perform(net,t,output);

tInd=tr.testInd;

tstOutputs=net(x(:,tInd));

tstPerform=perform(net,t(tInd),tstOutputs);
```

**EK 4. %80 EĞİTİM %20 TEST ORANI ve Bayesian Regularization Eğitim Fonksiyonu
ile 1 Gizli Katman ve Gizli katmanda 5 Nöron bulunan Yapay Sinir Ağı Modeline ait
oluşturulan MATLAB Kodları**

```
x=input;

t=target;

trainFcn='trainbr';

hiddenLayerSize=[5];

net=feedforwardnet(hiddenLayerSize,trainFcn);

net.layers{1}.transferFcn='tansig';

net.divideParam.trainRatio=80/100;

net.divideParam.testRatio=20/100;

net.performFcn='mse';

netplotFcn={'plotperform','plottrainstate','ploterrhist','plotregression'};

[net,tr]=train(net,x,t);

view(net);

output=net(x);

error=gsubtract(t,output);

performance=perform(net,t,output);

tInd=tr.testInd;

tstOutputs=net(x(:,tInd));

tstPerform=perform(net,t(tInd),tstOutputs);
```

**EK 5. %80 EĞİTİM %20 TEST ORANI ve Bayesian Regularization Eğitim Fonksiyonu
ile 2 Gizli Katman ve Gizli katmanlarda 5-10 Nöron bulunan Yapay Sinir Ağı Modeline
ait oluşturulan MATLAB Kodları**

```
x=input;

t=target;

trainFcn='trainbr';

hiddenLayerSize=[5 10];

net=feedforwardnet(hiddenLayerSize,trainFcn);

net.layers{1}.transferFcn='tansig';

net.layers{2}.transferFcn='logsig';

net.divideParam.trainRatio=80/100;

net.divideParam.testRatio=20/100;

net.performFcn='mse';

netplotFcn={'plotperform','plottrainstate','ploterrhist','plotregression'};

[net,tr]=train(net,x,t);

view(net);

output=net(x);

error=gsubtract(t,output);

performance=perform(net,t,output);

tInd=tr.testInd;

tstOutputs=net(x(:,tInd));

tstPerform=perform(net,t(tInd),tstOutputs);
```

**EK 6. %80 EĞİTİM %20 TEST ORANI ve Bayesian Regularization Eğitim Fonksiyonu
ile 3 Gizli Katman ve Gizli katmanlarda 5-10-15 Nöron bulunan Yapay Sinir Ağı
Modeline ait oluşturulan MATLAB Kodları**

```
x=input;

t=target;

trainFcn='trainbr';

hiddenLayerSize=[5 10 15];

net=feedforwardnet(hiddenLayerSize,trainFcn);

net.layers{1}.transferFcn='tansig';

net.layers{2}.transferFcn='logsig';

net.layers{3}.transferFcn='purelin';

net.divideParam.trainRatio=80/100;

net.divideParam.testRatio=20/100;

net.performFcn='mse';

netplotFcn={'plotperform','plottrainstate','ploterrhist','plotregression'};

[net,tr]=train(net,x,t);

view(net);

output=net(x);

error=gsubtract(t,output);

performance=perform(net,t,output);

tInd=tr.testInd;

tstOutputs=net(x(:,tInd));

tstPerform=perform(net,t(tInd),tstOutputs);
```

**EK 7. %80 EĞİTİM %20 TEST ORANI ve Scaled Conjugate Gradient Eğitim
Fonksiyonu ile 1 Gizli Katman ve Gizli katmanda 5 Nöron bulunan Yapay Sinir Ağı
Modeline ait oluşturulan MATLAB Kodları**

```
x=input;

t=target;

trainFcn='trainscg';

hiddenLayerSize=[5];

net=feedforwardnet(hiddenLayerSize,trainFcn);

net.layers{1}.transferFcn='tansig';

net.divideParam.trainRatio=80/100;

net.divideParam.testRatio=20/100;

net.performFcn='mse';

netplotFcn={'plotperform','plottrainstate','ploterrhist','plotregression'};

[net,tr]=train(net,x,t);

view(net);

output=net(x);

error=gsubtract(t,output);

performance=perform(net,t,output);

tInd=tr.testInd;

tstOutputs=net(x(:,tInd));

tstPerform=perform(net,t(tInd),tstOutputs);
```

**EK 8. %80 EĞİTİM %20 TEST ORANI ve Scaled Conjugate Gradient Eğitim
Fonksiyonu ile 2 Gizli Katman ve Gizli katmanlarda 5-10 Nöron bulunan Yapay Sinir
Ağı Modeline ait oluşturulan MATLAB Kodları**

```
x=input;

t=target;

trainFcn='trainscg';

hiddenLayerSize=[5 10];

net=feedforwardnet(hiddenLayerSize,trainFcn);

net.layers{1}.transferFcn='tansig';

net.layers{2}.transferFcn='logsig';

net.divideParam.trainRatio=80/100;

net.divideParam.testRatio=20/100;

net.performFcn='mse';

netplotFcn={'plotperform','plottrainstate','ploterrhist','plotregression'};

[net,tr]=train(net,x,t);

view(net);

output=net(x);

error=gsubtract(t,output);

performance=perform(net,t,output);

tInd=tr.testInd;

tstOutputs=net(x(:,tInd));

tstPerform=perform(net,t(tInd),tstOutputs);
```

**EK 9. %80 EĞİTİM %20 TEST ORANI ve Scaled Conjugate Gradient Eğitim
Fonksiyonu ile 3 Gizli Katman ve Gizli katmanlarda 5-10-15 Nöron bulunan Yapay
Sinir Ağı Modeline ait oluşturulan MATLAB Kodları**

```
x=input;

t=target;

trainFcn='trainscg';

hiddenLayerSize=[5 10 15];

net=feedforwardnet(hiddenLayerSize,trainFcn);

net.layers{1}.transferFcn='tansig';

net.layers{2}.transferFcn='logsig';

net.layers{3}.transferFcn='purelin';

net.divideParam.trainRatio=80/100;

net.divideParam.testRatio=20/100;

net.performFcn='mse';

netplotFcn={'plotperform','plottrainstate','ploterrhist','plotregression'};

[net,tr]=train(net,x,t);

view(net);

output=net(x);

error=gsubtract(t,output);

performance=perform(net,t,output);

tInd=tr.testInd;

tstOutputs=net(x(:,tInd));

tstPerform=perform(net,t(tInd),tstOutputs);
```

EK 10. %90 EĞİTİM %10 TEST ORANI ve Levenberg-Marquardt Eğitim Fonksiyonu ile 1 Gizli Katman ve Gizli katmanda 5 Nöron bulunan Yapay Sinir Ağı Modeline ait oluşturulan MATLAB Kodları

```
x=input;

t=target;

trainFcn='trainlm';

hiddenLayerSize=[5];

net=feedforwardnet(hiddenLayerSize,trainFcn);

net.layers{1}.transferFcn='tansig';

net.divideParam.trainRatio=90/100;

net.divideParam.testRatio=10/100;

net.performFcn='mse';

netplotFcn={'plotperform','plottrainstate','ploterrhist','plotregression'};

[net,tr]=train(net,x,t);

view(net);

output=net(x);

error=gsubtract(t,output);

performance=perform(net,t,output);

tInd=tr.testInd;

tstOutputs=net(x(:,tInd));

tstPerform=perform(net,t(tInd),tstOutputs);
```

EK 11. %90 EĞİTİM %10 TEST ORANI ve Levenberg-Marquardt Eğitim Fonksiyonu ile 2 Gizli Katman ve Gizli katmanda 5-10 Nöron bulunan Yapay Sinir Ağı Modeline ait oluşturulan MATLAB Kodları

```
x=input;

t=target;

trainFcn='trainlm';

hiddenLayerSize=[5 10];

net=feedforwardnet(hiddenLayerSize,trainFcn);

net.layers{1}.transferFcn='tansig';

net.layers{2}.transferFcn='logsig';

net.divideParam.trainRatio=90/100;

net.divideParam.testRatio=10/100;

net.performFcn='mse';

netplotFcn={'plotperform','plottrainstate','ploterrhist','plotregression'};

[net,tr]=train(net,x,t);

view(net);

output=net(x);

error=gsubtract(t,output);

performance=perform(net,t,output);

tInd=tr.testInd;

tstOutputs=net(x(:,tInd));

tstPerform=perform(net,t(tInd),tstOutputs);
```

**EK 12. %90 EĞİTİM %10 TEST ORANI ve Levenberg-Marquardt Eğitim Fonksiyonu
ile 3 Gizli Katman ve Gizli katmanda 5-10-15 Nöron bulunan Yapay Sinir Ağı Modeline
ait oluşturulan MATLAB Kodları**

```
x=input;

t=target;

trainFcn='trainlm';

hiddenLayerSize=[5 10 15];

net=feedforwardnet(hiddenLayerSize,trainFcn);

net.layers{1}.transferFcn='tansig';

net.layers{2}.transferFcn='logsig';

net.layers{3}.transferFcn='purelin';

net.divideParam.trainRatio=90/100;

net.divideParam.testRatio=10/100;

net.performFcn='mse';

netplotFcn={'plotperform','plottrainstate','ploterrhist','plotregression'};

[net,tr]=train(net,x,t);

view(net);

output=net(x);

error=gsubtract(t,output);

performance=perform(net,t,output);

tInd=tr.testInd;

tstOutputs=net(x(:,tInd));

tstPerform=perform(net,t(tInd),tstOutputs);
```

**EK 13. %90 EĞİTİM %10 TEST ORANI ve Bayesian Regularization Eğitim
Fonksiyonu ile 1 Gizli Katman ve Gizli katmanda 5 Nöron bulunan Yapay Sinir Ağı
Modeline ait oluşturulan MATLAB Kodları**

```
x=input;

t=target;

trainFcn='trainbr';

hiddenLayerSize=[5];

net=feedforwardnet(hiddenLayerSize,trainFcn);

net.layers{1}.transferFcn='tansig';

net.divideParam.trainRatio=90/100;

net.divideParam.testRatio=10/100;

net.performFcn='mse';

netplotFcn={'plotperform','plottrainstate','ploterrhist','plotregression'};

[net,tr]=train(net,x,t);

view(net);

output=net(x);

error=gsubtract(t,output);

performance=perform(net,t,output);

tInd=tr.testInd;

tstOutputs=net(x(:,tInd));

tstPerform=perform(net,t(tInd),tstOutputs);
```

**EK 14. %90 EĞİTİM %10 TEST ORANI ve Bayesian Regularization Eğitim
Fonksiyonu ile 2 Gizli Katman ve Gizli katmanda 5-10 Nöron bulunan Yapay Sinir Ağı
Modeline ait oluşturulan MATLAB Kodları**

```
x=input;

t=target;

trainFcn='trainbr';

hiddenLayerSize=[5 10];

net=feedforwardnet(hiddenLayerSize,trainFcn);

net.layers{1}.transferFcn='tansig';

net.layers{2}.transferFcn='logsig';

net.divideParam.trainRatio=90/100;

net.divideParam.testRatio=10/100;

net.performFcn='mse';

netplotFcn={'plotperform','plottrainstate','ploterrhist','plotregression'};

[net,tr]=train(net,x,t);

view(net);

output=net(x);

error=gsubtract(t,output);

performance=perform(net,t,output);

tInd=tr.testInd;

tstOutputs=net(x(:,tInd));

tstPerform=perform(net,t(tInd),tstOutputs);
```

**EK 15. %90 EĞİTİM %10 TEST ORANI ve Bayesian Regularization Eğitim
Fonksiyonu ile 3 Gizli Katman ve Gizli katmanda 5-10-15 Nöron bulunan Yapay Sinir
Ağı Modeline ait oluşturulan MATLAB Kodları**

```
x=input;

t=target;

trainFcn='trainbr';

hiddenLayerSize=[5 10 15];

net=feedforwardnet(hiddenLayerSize,trainFcn);

net.layers{1}.transferFcn='tansig';

net.layers{2}.transferFcn='logsig';

net.layers{3}.transferFcn='purelin';

net.divideParam.trainRatio=90/100;

net.divideParam.testRatio=10/100;

net.performFcn='mse';

netplotFcn={'plotperform','plottrainstate','ploterrhist','plotregression'};

[net,tr]=train(net,x,t);

view(net);

output=net(x);

error=gsubtract(t,output);

performance=perform(net,t,output);

tInd=tr.testInd;

tstOutputs=net(x(:,tInd));

tstPerform=perform(net,t(tInd),tstOutputs);
```

**EK 16. %90 EĞİTİM %10 TEST ORANI ve Scaled Conjugate Gradient Eğitim
Fonksiyonu ile 1 Gizli Katman ve Gizli katmanda 5 Nöron bulunan Yapay Sinir Ağı
Modeline ait oluşturulan MATLAB Kodları**

```
x=input;

t=target;

trainFcn='trainscg';

hiddenLayerSize=[5];

net=feedforwardnet(hiddenLayerSize,trainFcn);

net.layers{1}.transferFcn='tansig';

net.divideParam.trainRatio=90/100;

net.divideParam.testRatio=10/100;

net.performFcn='mse';

netplotFcn={'plotperform','plottrainstate','ploterrhist','plotregression'};

[net,tr]=train(net,x,t);

view(net);

output=net(x);

error=gsubtract(t,output);

performance=perform(net,t,output);

tInd=tr.testInd;

tstOutputs=net(x(:,tInd));

tstPerform=perform(net,t(tInd),tstOutputs);
```

**EK 17. %90 EĞİTİM %10 TEST ORANI ve Scaled Conjugate Gradient Eğitim
Fonksiyonu ile 2 Gizli Katman ve Gizli katmanlarda 5-10 Nöron bulunan Yapay Sinir
Ağı Modeline ait oluşturulan MATLAB Kodları**

```
x=input;

t=target;

trainFcn='trainscg';

hiddenLayerSize=[5 10];

net=feedforwardnet(hiddenLayerSize,trainFcn);

net.layers{1}.transferFcn='tansig';

net.layers{2}.transferFcn='logsig';

net.divideParam.trainRatio=90/100;

net.divideParam.testRatio=10/100;

net.performFcn='mse';

netplotFcn={'plotperform','plottrainstate','ploterrhist','plotregression'};

[net,tr]=train(net,x,t);

view(net);

output=net(x);

error=gsubtract(t,output);

performance=perform(net,t,output);

tInd=tr.testInd;

tstOutputs=net(x(:,tInd));

tstPerform=perform(net,t(tInd),tstOutputs);
```

**EK 18. %90 EĞİTİM %10 TEST ORANI ve Scaled Conjugate Gradient Eğitim
Fonksiyonu ile 3 Gizli Katman ve Gizli katmanlarda 5-10-15 Nöron bulunan Yapay
Sinir Ağı Modeline ait oluşturulan MATLAB Kodları**

```
x=input;

t=target;

trainFcn='trainscg';

hiddenLayerSize=[5 10 15];

net=feedforwardnet(hiddenLayerSize,trainFcn);

net.layers{1}.transferFcn='tansig';

net.layers{2}.transferFcn='logsig';

net.layers{3}.transferFcn='purelin';

net.divideParam.trainRatio=90/100;

net.divideParam.testRatio=10/100;

net.performFcn='mse';

netplotFcn={'plotperform','plottrainstate','ploterrhist','plotregression'};

[net,tr]=train(net,x,t);

view(net);

output=net(x);

error=gsubtract(t,output);

performance=perform(net,t,output);

tInd=tr.testInd;

tstOutputs=net(x(:,tInd));

tstPerform=perform(net,t(tInd),tstOutputs);
```