

**YAPAY SİNİR AĞLARI VE REGRESYON YÖNTEMLERİ
İLE HİSSE SENEDİ GETİRİLERİNİN TAHMİNİ: BİST-30
ÜZERİNE BİR UYGULAMA**

**PREDICTION OF STOCK RETURNS WITH ARTIFICIAL
NEURAL NETWORKS AND REGRESSION METHODS:
AN APPLICATION ON BIST-30**

NUR MİRAY AYTEKİN

PROF. DR. HÜSEYİN TATLIDİL

Tez Danışmanı

Hacettepe Üniversitesi
Lisansüstü Eğitim-Öğretim ve Sınav Yönetmeliğinin
İstatistik Anabilim Dalı için Öngördüğü
YÜKSEK LİSANS TEZİ olarak hazırlanmıştır.

2021

Burcu Zengin'e...

ETİK

Hacettepe Üniversitesi Fen Bilimleri Enstitüsü, tez yazım kurallarına uygun olarak hazırladığım bu tez çalışmada,

- tez içindeki bütün bilgi ve belgeleri akademik kurallar çerçevesinde elde ettiğimi,
- görsel, işitsel ve yazılı tüm bilgi ve sonuçları bilimsel ahlak kurallarına uygun olarak sunduğumu,
- başkalarının eserlerinden yararlanılması durumunda ilgili eserlere bilimsel normlara uygun olarak atıfta bulunduğumu,
- atıfta bulunduğum eserlerin tümünü kaynak olarak gösterdiğimi,
- kullanılan verilerde herhangi bir değişiklik yapmadığımı,
- ve bu tezin herhangi bir bölümünü bu üniversite veya başka bir üniversitede başka bir tez çalışması olarak sunmadığımı

beyan ederim.

26 / 05 / 2021

Nur Miray AYTEKİN

YAYINLANMA FİKRİ MÜLKİYET HAKKLARI BEYANI

Enstitü tarafından onaylanan lisansüstü tezimin/raporumun tamamını veya herhangi bir kısmını, basılı (kağıt) ve elektronik formatta arşivleme ve aşağıda verilen koşullarla kullanıma açma iznini Hacettepe Üniversitesine verdiğimi bildiririm. Bu izinle Üniversiteye verilen kullanım hakları dışındaki tüm fikri mülkiyet haklarım bende kalacak, tezimin tamamının ya da bir bölümünün gelecekteki çalışmalarda (makale, kitap, lisans ve patent vb.) kullanım hakları bana ait olacaktır.

Tezin kendi orijinal çalışmam olduğunu, başkalarının haklarını ihlal etmediğimi ve tezimin tek yetkili sahibi olduğumu beyan ve taahhüt ederim. Tezimde yer alan telif hakkı bulunan ve sahiplerinden yazılı izin alınarak kullanması zorunlu metinlerin yazılı izin alarak kullandığımı ve istenildiğinde suretlerini Üniversiteye teslim etmeyi taahhüt ederim.

Yükseköğretim Kurulu tarafından yayınlanan “*Lisansüstü Tezlerin Elektronik Ortamda Toplanması, Düzenlenmesi ve Erişime Açılmasına İlişkin Yönerge*” kapsamında tezim aşağıda belirtilen koşullar haricince YÖK Ulusal Tez Merkezi / H. Ü. Kütüphaneleri Açık Erişim Sisteminde erişime açılır.

- Enstitü / Fakülte yönetim kurulu kararı ile tezimin erişime açılması mezuniyet tarihimden itibaren 2 yıl ertelenmiştir.
- Enstitü / Fakülte yönetim kurulu gerekçeli kararı ile tezimin erişime açılması mezuniyet tarihimden itibaren ay ertelenmiştir.
- Tezim ile ilgili gizlilik kararı verilmiştir.

26 / 05 /2021

(İmza)

Nur Miray AYTEKİN

ÖZET

YAPAY SİNİR AĞLARI VE REGRESYON YÖNTEMLERİ İLE HİSSE SENEDİ GETİRİLERİNİN TAHMİNİ: BİST-30 ÜZERİNE BİR UYGULAMA

Nur Miray AYTEKİN

Yüksek Lisans Tezi, İstatistik Bölümü

Tez Danışmanı: Prof. Dr. Hüseyin TATLIDİL

Mayıs 2021, 114 sayfa

Son yıllarda dünya üzerinde teknolojinin hızla gelişme göstermesiyle birlikte yapay zekâ alanında da birçok yenilik ortaya çıkmıştır. Bu yeniliklerle birlikte yapay zekanın en çok kullanım alanlarından birisi de finans olmuştur. Gelecek tahmininde bulunmak finans alanında sıkça ihtiyaç duyulan bir durumdur. Tahminde bulunabilmek için kullanılan birçok istatistiksel metot bulunmaktadır. Bu metotlar arasında en çok tercih edilenlerden birisi de Yapay Sinir Ağları (YSA)'dır.

Bu tez çalışmasında da BİST-30'da yer alan hisse senetlerinden rasgele seçilmiş 12 tanesinin 2019 ve 2020 yıllarına ait üçer aylık dönemlerin kapanış fiyatları alınarak 3 farklı portföy oluşturulmuştur. Oluşturulan portföyler bazı finansal kriterler göz önünde bulundurularak önce panel regresyon analizi ile incelenmiştir. Sonrasında Yapay Sinir Ağları ve Regresyon Analizi ile hisse senedi kapanış fiyatları tahmin edilmiştir. Bulunan sonuçlar karşılaştırılmış ve Yapay Sinir Ağları yöntemi ile elde edilen sonuçların performans kriterlerine göre daha başarılı olduğu görülmüştür.

Anahtar Kelimeler: Yapay Sinir Ağları, Portföy Analizi, Çoklu Regresyon Analizi, Panel Regresyon Analizi

ABSTRACT

PREDICTION OF STOCK RETURNS WITH ARTIFICIAL NEURAL NETWORKS AND REGRESSION METHODS: AN APPLICATION ON BIST-30

Nur Miray AYTEKİN

M.Sc. Thesis, Department of Statistics

Supervisor: Prof. Dr. Hüseyin TATLIDİL

May 2021, 114 pages

With the rapid development of technology in the world in recent years, many innovations have emerged in the field of artificial intelligence. With these innovations, one of the most used areas of artificial intelligence has been finance. Predicting the future is often needed in finance. There are many statistical methods used to make predictions. Among these methods, Artificial Neural Networks (ANN) is one of the most preferred methods. In this thesis, 3 different portfolios were created by taking the closing prices of the 12 stocks included in BIST-30 for the three-month periods of the years 2019 and 2020. The portfolios created were first examined by panel regression analysis, considering some financial criteria. Afterwards, the closing prices of the stocks were estimated by using Artificial Neural Networks and Regression Analysis. The results were compared and it was seen that the results obtained with the Artificial Neural Networks method were more successful than the performance criteria.

Keywords: Artificial Neural Networks, Portfolio Analysis, Multiple Regression Analysis, Panel Regression Analysis.

TEŐEKKÜR

Yüksek lisans programım sürecinde görüşleriyle, engin bilgi ve tecrübeleriyle teze yön veren, içten ve sabırlı tutumuyla her daim yanımda olan değerli hocam Prof. Dr. Hüseyin Tatlıdil'e, hayatımın her aşamasında ve her kararında benim arkamda olan, bu süreci tamamlayabilmem için bana olan güvenini her daim hissettiren canım kardeşim Burcu Zengin'e, bugünlere gelmemi sağlayan annem Nalan Aytekin, babam Ayhan Aytekin'e ve her zaman yanımda olan kardeşim Ekin Aytekin'e en içten sevgi, saygı ve teşekkürlerimi sunarım.

İÇİNDEKİLER

ABSTRACT.....	ii
TEŞEKKÜR.....	iii
İÇİNDEKİLER	iv
ŞEKİLLER DİZİNİ	vii
ÇİZELGELER DİZİNİ.....	viii
SİMGELER VE KISALTMALAR	x
1. GİRİŞ.....	1
2. YAPAY SİNİR AĞLARI	3
2.1. Yapay Sinir Ağlarının Özellikleri.....	4
2.2. Yapay Sinir Ağlarının Tarihsel Gelişimi	5
2.3. YSA'nın Uygulama Alanları	6
3. YSA'NIN YAPISI VE TEMEL BİLEŞENLERİ	8
3.1. Biyolojik Sinir Ağlarının Yapısı.....	8
3.2. Yapay Sinir Ağlarının Yapısı	9
3.2.1. Girdiler.....	10
3.2.2. Ağırlıklar.....	11
3.2.3. Toplama Fonksiyonu	11
3.2.4. Aktivasyon (Transfer) Fonksiyonu	12
3.2.5. Çıktı	14
4. YAPAY SİNİR AĞLARININ SINIFLANDIRILMASI VE ÖĞRENME ALGORİTMALARI	15
4.1. YSA'nın Sınıflandırılması	15
4.1.1. YSA'nın Yapısına (Topolojilerine) Göre Sınıflandırılması	15
4.1.2. YSA'nın Öğrenme Algoritmalarına Göre Sınıflandırılması.....	17
4.1.3. YSA'nın Uygulama Alanlarına Göre Sınıflandırılması.....	19
4.2. Yapay Sinir Ağlarında Temel Öğrenme Kuralları.....	19

4.3.	Yapay Sinir Ağı Modelleri	21
4.3.1.	Tek Katmanlı YSA	21
4.3.2.	Çok Katmanlı YSA	24
4.3.3.	Kohonen Ağı.....	26
4.3.4.	ART (Uyarlanabilir Rezonans Teorisi-Adaptive Resonance Theory) Ağları 26	
4.3.5.	Hopfield Ağı	27
4.3.6.	Jordan Ağı.....	29
4.3.7.	Elman Ağı	29
4.4.	YSA ile Modelleme	30
5.	PORTFÖY OPTİMİZASYONU	37
5.1.	Portföyün Tanımı.....	37
5.2.	Portföy Optimizasyonu	37
5.3.	Portföy Yönetimi	38
5.4.	Portföy ile İlgili Temel Kavramlar	38
5.4.1.	Portföy Çeşitleri.....	45
5.5.	Optimum Portföy	46
5.6.	Menkul Kıymet Seçimi	46
5.6.1.	Temel Analiz.....	46
5.6.2.	Teknik Analiz	48
5.7.	Portföy Yönetimi Yaklaşımları.....	49
5.7.1.	Geleneksel Portföy Teorisi	49
5.7.2.	Modern (Markowitz) Portföy Teorisi	50
5.7.3.	Modern Portföy Modelinin Çeşitlendirilmesi.....	60
6.	YSA İLE FİNANSIN TARİHSEL GELİŞİMİ.....	61
7.	REGRESYON ANALİZİ	64
7.1.	Tek Değişkenli (Basit) Regresyon Analizi	64
7.1.1.	Belirtme Katsayısı.....	66
7.2.	Çoklu Regresyon Analizi.....	67
7.2.1.	Çoklu Belirtme Katsayısı.....	67
7.3.	Panel Regresyon (Veri) Analizi	68
7.3.1.	Panel Birim Kök Testleri	69
7.3.2.	Panel Regresyon Modelleri.....	70
8.	UYGULAMA	72
8.1.	Çalışmada Kullanılacak Değişkenler.....	72

8.1.1. Bağımlı Değişken	73
8.1.2. Bağımsız Değişkenler	73
8.2. Çalışmada Kullanılan Hisse Senetleri.....	74
8.3. Panel Regresyon Analizi.....	75
8.4. Klasik Çoklu Regresyon Analizi Kullanarak Portföy Değerlendirmesi	77
8.4.1. Normal Dağılıma Uygunluk	78
8.4.2. Çoklu Doğrusal Bağımlılığın Sınanması	79
8.4.3. Otokorelasyonun Sınanması	81
8.4.4. Değişen Varyanslılık.....	82
8.5. YSA ile Portföy Değerlendirmesi.....	92
9. SONUÇ VE ÖNERİLER.....	100
10. KAYNAKLAR	103
ÖZGEÇMİŞ	114

ŞEKİLLER DİZİNİ

Şekil 3.1. Biyolojik bir nöron (Mehrotra vd., 1997).....	8
Şekil 3.2. Bir nöron modeli (Gurney, 1996).....	10
Şekil 4.1. İleri-Geri Beslemeli Ağ Mimarisinin Bir Taksonomisi (Jain ve Mao, 1996). 15	
Şekil 4.2. İleri Beslemeli Çok Katmanlı Yapay Sinir Ağı Modeli (Öztemel, 2003).....	16
Şekil 4.3. Geri Beslemeli Yapay Sinir Ağı Modeli (Diler, 2003).	17
Şekil 4.4. Danışmanlı Öğrenme Algoritmalarının İşleyişi (Hamzaçebi, 2005).....	18
Şekil 4.5. Tek Katmanlı Bir Yapay Sinir Ağı Modeli.	21
Şekil 4.6. Basit Algılayıcı Modeli.	22
Şekil 4.7. İki ADALINE Ağından Oluşan Bir MADALINE Ağı.	23
Şekil 4.8. LVQ Ağı'nın Topolojik Yapısı.....	25
Şekil 4.9. Kohonen Ağı (Fröhlich, 1997).	26
Şekil 4.10. ART Ağlarının Yapısı (Kröse ve van der Smagt,1996).	27
Şekil 4.11. Hopfield Ağı (Sağiroğlu vd. 2003).....	28
Şekil 4.12. Jordan Ağı (Kröse ve van der Smagt,1996).	29
Şekil 4.13. Elman Ağı Yapısı (Kröse ve van der Smagt, 1996).	30
Şekil 5.1. Portföy Optimizasyon Süreci (Mansini vd., 2015).....	38
Şekil 5.2. Etkin Sınır ve Erişilebilen Portföyler (Dağlı, 2004).....	54
Şekil 5.3. Sermaye Piyasası Doğrusu	58
Şekil 8.1. Portföy 1 için Test Kümesi Karşılaştırması.....	95
Şekil 8.2.Portföy 2 için Test Kümesi Karşılaştırması.....	97
Şekil 8.3.Portföy 3 için Test Kümesi Karşılaştırması.....	99

ÇİZELGELER DİZİNİ

Çizelge 2.1. YSA'larının Kullanım Alanları	7
Çizelge 3.1. Nöronlar ve İşleme Elemanları (PE)'nin Benzerlikleri (Flores, 2011).	10
Çizelge 3.2. Toplama Fonksiyonları ve Özellikleri (Öztemel, 2003).....	11
Çizelge 4.1. Performans Ölçütleri.....	36
Çizelge 7.1. Varyans Analizi	66
Çizelge 8.1. Bağımlı ve Bağımsız Değişkenler	72
Çizelge 8.2. Hisse Senetleri ve Sektörler.....	74
Çizelge 8.3. Portföylerin Dağılımı.....	75
Çizelge 8.4. Fisher ADF Birim Kök Testi Sonuçları.....	75
Çizelge 8.5. Hausman Testi Sonuçları.....	76
Çizelge 8.6. Rassal Etkiler Modeli Sonuçları	77
Çizelge 8.7. Jarque- Bera Testi	78
Çizelge 8.8.Portföylere İlişkin Özet İstatistikler	79
Çizelge 8.9. VIF Değerleri.....	80
Çizelge 8.10. VIF Değerleri (Düzeltilmiş)	80
Çizelge 8.11. Durbin Watson Test Sonuçları	81
Çizelge 8.12. Durbin Watson Test Sonuçları (Düzeltilmiş).....	82
Çizelge 8.13. White Testi	82
Çizelge 8.14. Çalışmada Kullanılan Finansal Oranların Değerleri	82
Çizelge 8.15. Portföy 1 için Regresyon Analizi Sonuçları	85
Çizelge 8.16. Korelasyon Değerleri.....	86
Çizelge 8.17. Portföy 2 için Regresyon Analizi Sonuçları	86
Çizelge 8.18. Korelasyon Değerleri.....	87
Çizelge 8.19. Portföy 3 için Regresyon Analizi Sonuçları	87
Çizelge 8.20. Korelasyon Değerleri.....	88
Çizelge 8.21. Regresyon Tahmini ile Hisse Senedi Fiyatları	89
Çizelge 8.22. Regresyon Tahmini ile Hisse Senedi Fiyatları	90
Çizelge 8.23. Regresyon Tahmini ile Hisse Senedi Fiyatları	91
Çizelge 8.24. Performans Ölçütleri.....	92
Çizelge 8.25. Gizli Katmandaki Nöron Sayılarına göre Model Karşılaştırması	94
Çizelge 8.26. YSA Sonucu Bulunan Test kümesinin Tahmini Değerleri ile Gerçek Değerlerinin Karşılaştırılması.....	95

Çizelge 8.27. Gizli Katmandaki Nöron Sayılarına göre Model Karşılaştırması	96
Çizelge 8.28. YSA Sonucu Bulunan Test Kümesinin Tahmini Değerler ile Gerçek Değerlerin Karşılaştırılması	97
Çizelge 8.29. Gizli Katmandaki Nöron Sayılarına göre Model Karşılaştırması	98
Çizelge 8.30. YSA Sonucu Bulunan Test Kümesinin Tahmini Değerler ile Gerçek Değerlerin Karşılaştırılması	99
Çizelge 8.31. Performans Göstergeleri	101

SİMGELER VE KISALTMALAR

Simgeler

λ	Eğim Parametresi
PE	Nöronlar ve İşleme Elemanları
Θ	Eşik Değeri
γ	Momentum Katsayısı
μ	Ortalama
σ^2	Varyans
β	Beta Katsayısı
ϵ	Hata Katsayısı
σ	Standart Sapma
ρ	Korelasyon Katsayısı

Kısaltmalar

YSA	Yapay Sinir Ağları
BİST	Borsa İstanbul A.Ş
BİST-30	Borsa İstanbul 30 Endeksi
BİST-100	Borsa İstanbul 100 Endeksi
ADALINE	Adaptif Lineer Eleman (Adaptive Linear Neurons)
MADALINE	Çoklu Adaptif Lineer Eleman (Multi Adaptive Linear Neurons)
LVQ	Learning Vector Quantization
MLP	Çok Katmanlı Algılayıcı
OMH	Ortalama Mutlak Hata
GA	Genetik Algoritmalar
OMYH	Ortalama Mutlak Yüzde Hatası
HKO	Hata Kareler Ortalaması
HKOK	Hata Kareler Ortalaması Karesi
SOM	Self Organization Feature Map Network
ART	Adaptive Resonance Theory

OS	Ortalama Sapma
GSMH	Gayri Safi Milli Hasıla
SVFM	Sermaye Varlıklarının Fiyatlama Modeli
AFT	Arbitraj Fiyatlama Teorisi
SA	Tavlama Benzetimi
TS	Tabu Araştırması
HO	Basit Hareketli Ortalamalar
HBK	Hisse Başına Kar
ÖSK	Öz Sermaye Karlılığı
PD	Piyasa Deęeri
DD	Defter Deęeri
KO	Kaldıraç Oranı
F	Fiyat Oranı
K	Kazanç Oranı
ADF	Augmented Dickey-Fuller
PP	Phillips-Perron
VIF	Varyans Şişkinlik Faktörü

1. GİRİŞ

Son yıllarda teknolojinin de hızlı gelişme göstermesiyle birlikte yapay zekâ alanında yer alan birçok teknik de kendine uygulama alanı bulmuştur. Bu alanlar arasında en çok tercih edilenlerden birisi de finanstır. Gelecek tahmininde bulunmak finans alanında sıkça ihtiyaç duyulan bir durumdur. Tahminde bulunabilmek için kullanılan birçok istatistiksel metot bulunmaktadır. Bu metotlardan en çok tercih edilenlerden birisi de Yapay Sinir Ağları (YSA) olmuştur. YSA birbirine bağlı olarak bulunan birçok nörondan oluşmuş matematiksel bir modeldir. Yapay sinir ağları, doğrusal olmayan yapılarda tahminde bulunurken klasik istatistik yöntemlerine göre kolaylık sağlamaktadır. YSA'nın öğrenme yeteneği, hızı, kendi kendini eğitebilmesi ve minimum veriyle sonuçlar çıkarabilmesi diğer istatistiksel yöntemlere göre daha çok tercih edilmesini sağlamaktadır.

Yatırımcıların yatırım kararı verebilmesi için hem risk-getiri faktörleri hem de kişisel tercihleri göz önünde bulundurulmaktadır. Oluşturulan modellerin yatırımcıya göre kişiselleştirilebilmesi için klasik istatistiksel yöntemler ve yapay sinir ağları gibi yöntemlerden faydalanılabilir.

Bu tez çalışmasında amaç, başarılı öngörüler yapmak suretiyle getiri sağlamak ve risklerden korunmak isteyen yatırımcılara hisse senedi fiyat tahminine yönelik bir YSA model önerisinde bulunmaktadır.

BİST-30 kapsamında bulunan hisse senetlerinin 3'er aylık kapanış fiyatları göz önünde bulundurularak doğrusal olmayan bir yöntem olan YSA modeli ile maksimum getiri minimum risk elde edilmesi hedeflenmiştir. YSA'nın performansını 7 faktör belirlemektedir. Bunlar; öğrenme katsayısı, momentum terimi, gizli katman sayısı, gizli katmandaki işlem elemanı sayısı, eğitim algoritması, transfer fonksiyonu ve hata düzeyinden oluşmaktadır. Bu zamana kadar yapılan çalışmalarda her bir problem için geçerli olan genel bir yapay sinir ağı modeli geliştirilememiştir. Bunun için öncelikle yapay sinir ağı oluşturulacak ve oluşturulan YSA'nın eğitimi tamamlanacaktır. Oluşturulan portföyler aynı şekilde klasik istatistik yöntemlerinden birisi olan çoklu regresyon analizi ile de modellenecek ve kurulan modellerin performansları birbirleriyle karşılaştırılacaktır.

Bu çalışma giriş dahil olmak üzere dokuz ana bölümden oluşmaktadır.

İkinci bölümde, yapay sinir ağlarının genel özellikleri, tarihsel gelişimi ve kullanım alanları hakkında detaylı bir şekilde bahsedilmiştir.

İzleyen üçüncü bölümde, konunun daha detaylı anlaşılabilmesi için öncelikle biyolojik sinir ağlarına, sonrasında yapay sinir ağlarının yapısına yer verilmiştir.

Çalışmanın dördüncü bölümünde YSA'nın sınıflandırılması, temel öğrenme algoritmaları, bazı sinir ağ modelleri ve sinir ağının modellenmesi için gerekli işlem basamakları detaylı bir şekilde anlatılmıştır.

Beşinci bölümde, portföyün tanımı ve portföy yönetimi hakkında genel bilgiler verilmiştir. Finansal varlıklarla ilgili temel tanım ve hesaplamalara yer verilmiştir. Menkul kıymet seçiminde hangi tekniklerin kullanıldığı ve portföy yönetimi yaklaşımları anlatılmıştır.

Çalışmanın altıncı bölümünde yapay sinir ağlarının finans alanında kullanımına ilişkin literatür taraması yer almaktadır.

Yedinci bölümde çoklu regresyon analizi ve panel veri analizine ilişkin genel bilgilere yer verilmektedir.

Sekizinci bölümde ise BİST-30'listesinden seçilmiş bir grup hisse senedine panel veri analizi, YSA ve çoklu regresyon analizi uygulamaları yapılmıştır, son bölüm olan dokuzuncu bölümde ise uygulamada elde edilen bulgular ve sonuçların değerlendirildiği tartışma bölümü yer alacaktır.

2. YAPAY SİNİR AĞLARI

Yapay Sinir Ağları (YSA) son yıllarda teknolojinin de ilerlemesiyle birlikte hem gelişme göstermiş hem de üzerinde yapılan çalışmalara ilgi artmıştır. Yapay Sinir Ağları beyindeki biyolojik sinir hücrelerini taklit ederek problemlere çözüm üretmeye çalışan bir analizdir.

İnsan beyninin yapısı çok karmaşık olduğu için YSA beynin yaptığı işlemleri birebir gerçekleştirememektedir. Buna rağmen beyinde yapılan işlemler YSA 'ya ne kadar fazla öğretilirse problemlerin çözüm de o kadar kolaylaşmaktadır. Bu amaç doğrultusunda da insan beyninin çalışma prensibi üzerine oldukça fazla yoğunlaşmıştır (Kasabov, 1996).

İnsanların doğumlarından itibaren karşılaştıkları problemleri çözebilmelerinin temel nedeni "Yaşayarak Öğrenme" sürecidir. Bu öğrenme sürecinde beyin sürekli olarak gelişir ve bu gelişim esnasında sinapslar (sinir hücrelerinin birbirleriyle bağlantı noktaları) arasında yeni bağlantılar kurulur. Bunun sonucunda öğrenme eylemi gerçekleşmiş olur. Aynı durum YSA'ların öğrenme sürecinde de gerçekleşir. Öğrenme sinir hücrelerinin eğitilmesi sonucu yani girdi-çıktı da kullanılan bilgilerin işlenmesiyle elde edilir. YSA'lar sinir hücreleri üzerindeki ağırlıklarla birbirlerine bağlanmış olan nöronlardan oluşurlar (Yurtoğlu, 2005).

Yaklaşık 40 yıl önce ilk çalışmaların başladığı YSA için literatürde geçen bazı tanımlar ve gelişmeler özet olarak verilmek istenirse şu şekildedir:

1989 yılında Darpa tarafından yapılan Neural Network Study isimli çalışmada "YSA, birbirlerine paralel olarak çalışan birçok basit işlem elemanından oluşan ve fonksiyonu, ağırlık yapısı, bağlantı ağırlıkları ve elemanlarda gerçekleştirilen işlemler tarafından belirlenen bir sistemdir" şeklinde tanımlanmaktadır (Darpa, 1989).

Haykin (1999) göre YSA, "bir sinir ağı, basit işlem birimlerinden oluşan, deneysel bilgileri biriktirmeye yönelik doğal bir eğilimi olan ve bunların kullanılmasını sağlayan yoğun bir şekilde paralel dağıtılmış bir işlemcidir. Bu işlemci iki farklı şekilde beyin ile benzerlik göstermektedir:

1. Bilgi, ağ tarafından öğrenme süreciyle çevreden elde edilir.

2. Elde edilen bilgileri biriktirmek için sinaptik ağırlıklar (synaptic weights) olarak da bilinen nöronlar arası bağlantı güçleri kullanılır” (Haykin, 1999).

2.1.Yapay Sinir Ağlarının Özellikleri

YSA'nın hesaplama, öğrenme, eğitilebilme, veri işleme ve genelleme gibi özelliklerini paralel yapısından aldığı söylenebilir. Karmaşık birçok problem bu özellikler sayesinde çözülebilmektedir.

Öğrenme: Önceki örnekler aracılığıyla sinir ağını eğiterek ağın istenilen davranışı göstermesi sağlanabilmektedir. YSA kendilerine gösterilen örnekleri öğrenebilmeleri anlamında sürekli olarak öğrenme potansiyeli içerisindedirler. Böylelikle klasik yöntemlerle çözülmekte zorlanılan karmaşık birçok probleme çözüm bulunabilmektedir.

Doğrusal Olmama: Hücreler gibi yapay sinir ağları da doğrusal değildir. Bu nedenle yapay sinir ağları doğrusal olmayan komplike problemlerin de çözümünü kolaylaştırmaktadır.

Genelleme: YSA kendi kendilerine öğrenme yetenekleri sayesinde daha önce ilgilenilmemiş bir problem hakkında bile bir çözüm üretebilir.

Uygulanabilirlik: YSA ağırlıkları uygulanan probleme göre değişebilir. Başka bir ifadeyle çözülmesi gereken probleme göre eğitilen yapay sinir ağı, problemde oluşabilecek her türlü değişim karşısında yeniden eğitilebilir (Öztemel, 2012).

Hata Toleransı: Yapay sinir ağları, birçok hücreden oluşur ve hücreler birbirlerine paralel bir şekilde bağlanarak ağı oluştururlar. Bir hücre üzerinde bilgi paralel bağlanmalar nedeni ile ağıdaki tüm bağlantılar üzerine dağılmış durumdadır. Bu nedenle hücrelerden birinin zarar görmesi problemin sonuçlanmasını önemli derecede etkilemez. Bu durum YSA için hata toleransının çok yüksek olduğunu gösterir.

Eksik Verilerle Çalışma: YSA eğitimini tamamladıktan sonra verileri eksik olsa bile çalışabilmektedir. Eksik olan verinin ne derece önemli olduğuna eğitiminden sonra kendisi karar vermektedir (Bayır, 2006).

2.2.Yapay Sinir Ağlarının Tarihsel Gelişimi

Yapay sinir ağları ile ilgili çalışmalar çok uzun yıllardır devam etmektedir. Bu çalışmalara insanların nörobiyoloji alanına ilgilerinin artmasıyla ve elde edilen çalışmaların bilgisayar bilimi ile birlikte yürütülmesiyle başlanmıştır. Bu konu hakkındaki ilk çalışmalar 1943 yılında nörofizyolojist McCulloch ve matematikçi Pitts tarafından nöronların çalışma prensibiyle ilgili yayınladıkları makale ile ortaya atılmıştır (Anderson ve McNeil, 1992). Bu çalışmada elektrik devrelerinden yararlanarak basit bir sinir ağı modeli ortaya çıkarmışlardır. Bu model yapay sinir ağlarının ilk matematiksel modelini oluşturmaktadır. 1949 yılında Donald Hebb tarafından “The Organization of Behavior” isimli bir kitap yayınlanmıştır. Kitabın içeriğinde sinir ağlarının yapısı ve çalışma prensiplerine yönelik detaylı bilgilere yer verilmektedir (Saraç, 2004).

1950’li yıllarda IBM laboratuvarlarında çalışmakta olan Nathaniel Rochester sinir ağı oluşturmak için çalışmalar gerçekleştirmiş fakat başarılı olamamıştır. Daha sonraki çalışmalarda başarılı olunmuş ve yapay sinir ağlarında yeni bir döneme adım atılmıştır. 1956 yılında “Yapay Zekâ Dartmouth Summer Araştırma Projesi” yapılmıştır. Bu çalışmayla birlikte yapay zekâ alanında ümit verici gelişmeler sağlanmıştır. Rochester, Misnky, Shannon ve McCarthy iki ay süren bu çalışmaya dahil olmuşlardır. “Yapay Zekâ” kelimesi bu projede McCarthy tarafından önerilmiştir ve kullanılmaya başlanmıştır (Sağiroğlu vd., 2003). Nörobiyolog olan Frank Rosenblatt 1957 yılında bir böceğin gözünün çalışmasıyla ilgilenmiştir. Sineğe komutları beyin yerine gözünün verdiği fikrinden esinlenilerek algılayıcı olarak adlandırılan bir sinir ağı modellenmiştir (Anderson ve McNeil, 1992; Elmas, 2003). Bu model günümüzde de hala kabul görmektedir ve en eski sinir ağı modeli olarak bilinmektedir.

Bernard Widrow ve Marcian Hoff tarafından 1959 yılında ADALINE ve MADALINE olarak adlandırılan iki model öne sürülmüştür. ADALINE, mühendislik alanında sinir ağlarının kullanımına ilişkin atılan ilk adımlardan biri olarak kabul edilmektedir. MADALINE ise gerçek hayattaki problemlere uygulanabilen ilk sinir ağı olarak bilinmektedir. Telefon hatlarında oluşan yankıları ortadan kaldıran bir filtre yapımı için kullanılması ile de gerçek problemlere uygulanabilir olduğunu kanıtlamıştır (Öztemel, 2003).

Art arda gelen bu başarılar yapay zekanın insanoğlunu nasıl etkileyeceği konusunda tartışmalara yol açmıştır. O dönemdeki birçok bilim kurgu yazarları “düşünen makinelerin” insanoğlunu nasıl etkileyeceğini konu almaya başlamıştır. Bunlardan biri olan Asimov, insanın yaptığı her şeyi yapabilecek makinelerin olmasının insanlığın değer yargılarını nasıl etkileyeceğini konusuna değinmiştir. Yine aynı şekilde konu birçok film senaryosuna konu olmuştur. Yaşanan bu gelişmelerden sonra yapay zekâ alanında 1982 yılına kadar devam eden bir durgunluk dönemi başlamıştır (Anderson ve McNeil, 1992).

Bu durgunluk döneminden sonra 1982 yılında teknolojinin de gelişmesi ile birlikte yeni alanlarda çalışmalar ortaya çıkmıştır. Hopfield tarafından sunulan makalede klasik programlama ile çözülemeyen modellerin YSA ile çözülebileceği ortaya konmuştur (Öztemel, 2003). Aynı zamanda bu çalışma da YSA'nın matematiksel modeli de ortaya koyulmuştur (Anderson ve McNeil, 1992).

1985 yılında Amerikan Fizik Enstitüsü tarafından “Bilgi İşlemek İçin Yapay Sinir Ağları” üzerine bir toplantı yapılmıştır. Bu toplantı da birçok çalışma sunulmuş ve YSA'nın dünya genelinde yaygınlaşması amaçlanmıştır (Sağiroğlu, 2003).

Günümüzde, yapay sinir ağları ile ilgili çalışmalar tüm dünya genelinde hala devam etmektedir. Yapılan çalışmalar ve oluşturulan sistemlerin artık uygulamada da insanlara faydalı olduğu görülmektedir (Öztemel, 2003).

2.3.YSA'nın Uygulama Alanları

YSA özellikle son yıllarda gerçek hayattaki yaşanan problemlerin çözümünde büyük gelişme gösteren bir alandır. Her geçen gün üzerinde yapılan çalışmalar artmaktadır ve bu sayede birçok alanda adını duyurmayı başarmıştır. Doğrusal olmayan, eksik, kusurlu, çok boyutlu gibi verilerin belli bir matematiksel modelinin bulunmaması nedeniyle bu tarz problemlerin çözümünde yapay sinir ağları oldukça başarılı sonuçlar vermektedir.

YSA,

- Optimizasyon,
- Özellik belirleme,
- Tahmin,
- Genelleme,

- Sınıflandırma,
- İlişkilendirme,
- Öğrenme,
- Örüntü tanıma,
- Yorumlama,

gibi çeşitli konularda kullanılmaktadırlar.

YSA'ların gerçek hayatta da birçok uygulama alanı olmasına rağmen genel olarak yaygın uygulandığı alanlar aşağıdaki gibi ifade edilebilir.

Çizelge 2.1. YSA'larının Kullanım Alanları

ÖRÜNTÜ TANIMA	VERİLERİN YORUMLANMASI	DİĞER
Ses tanıma	Finans alanı	Kontrol
Veri iletimi	Güvenlik sistemleri	Arama çalışmaları
Hareket tespiti, yüz tanıma, hedef tespiti	Jet ve roket motorlarının geliştirilmesi	Verilerin sınıflandırılması
Robotik sistemler	Hava durumu tahminleri	Verilerin taklit edilmesi
Karakter, imza, parmak izi tanıma	Personel seçimi	
Kalite kontrolü	Optimizasyon işlemleri	
	Fonksiyon yaklaşımları	

3. YSA'NIN YAPISI VE TEMEL BİLEŞENLERİ


Yapay sinir ağlarının oluşturulmasında biyoloji sinir ağlarının ağlarından esinlenilmiş olmasına rağmen, hala biyolojik sinir sistemleri ile yapay sinir ağları arasında hem mimarileri hem de yetenekleri yönünden farklılıklar bulunmaktadır. Hiçbir model insan beyninin performansının aynısını taklit etmede başarılı olamamıştır (Aladağ vd., 2007). Bu bölümde YSA'nın yapısı ve temel elemanları incelenecektir. YSA biyolojik sinir ağlarının taklidi olması nedeni ile daha iyi anlaşılabilmesi için ilk olarak biyolojik sinir ağlarının yapısı incelenecektir.

3.1. Biyolojik Sinir Ağlarının Yapısı

Biyolojik sinir ağlarının yapısını nöronlar oluşturmaktadır. Nöronlar; insan beyinde bulunan sinir hücreleridir ve merkezi sinir sisteminin temel elemanıdır.

Nöronlar, genel işleyişlerinde ve biyokimyasal sistemlerinde diğer hücelere göre çok sayıda noktaya ve farklı özelliklere sahiptirler (Davalo ve Naim, 1991). Her bir sinir hücresi kendine özgü yapı ve şekillere sahip olsalar dahi hepsinin sahip olduğu ortak 3 bölge bulunmaktadır. Bunlar;

- Hücre gövdesi,
- Dendrit,
- Akson



Şekil 3.1. Biyolojik bir nöron (Mehrotra vd., 1997).

Hücre gövdesi; kendisine ait bir çekirdeğe sahiptir.

Dendritler; her biri bir hücre gövdesine bağlı olan ve uzayda diğer nöronlardan sinyalleri almaya yarayan dallardır.

Akson; nöronların ileticisi görevindedir.

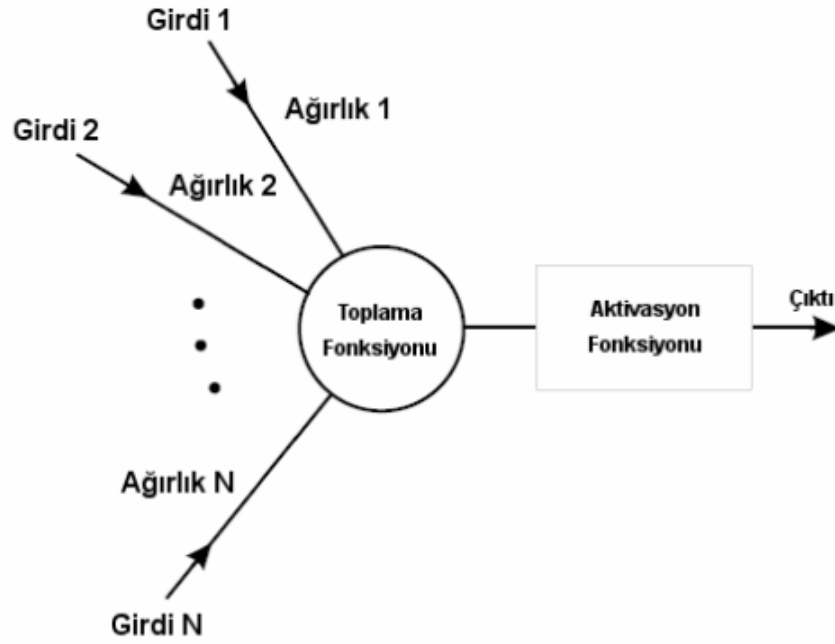
İki farklı nöronun arasındaki iletişimi sinapslar sağlamaktadır. Yani herhangi bir nöronun aksonunun bitişiyle komşu nöronunun dendritiği arasındaki etkileşim sinapslar sayesinde gerçekleşir ve elektrokimyasal sinyaller sinaps boyunca iletilir. Bir sinir ağına ulaşan toplam sinyal miktarı sinaps eşliğinden yüksek olursa o sinir hücresinin ateşlenmesine sebep olur. Bu ateşlenme sonucunda sinir hücresi komşu sinir hücrelerine elektrokimyasal bir sinyal gönderir (Cartwright, 2009).

3.2.Yapay Sinir Ağlarının Yapısı

Yapay sinir ağları, birbirine bağlı yapay nöronları içeren bir ağ yapısına sahiptir. Yapay sinir ağı mimarisinin temel birimi olan her bir nöron için, nörona gelen girdi değeri ve bu nöronun diğer nöron veya nöronlara ilettiği bir çıktı değeri vardır. Nörona gelen girdi değeri tek bir nörondan gelen çıktı değeri olabileceği gibi birden fazla nörondan gelen çıktı değerlerinin toplamı da olabilir. Nöronun aldığı bu girdi değeri bir fonksiyon yardımıyla çıktı değerine dönüştürülür ve diğer nöron ya da nöronlara girdi değeri olarak iletilir. Bir nöronun çıktı değerinin diğer bir nörona girdi değeri olarak iletilmesi işleme sinyal akışı adı verilmektedir (Aladağ vd., 2007).

YSA'nın yapısı 3 katmandan oluşmaktadır. YSA'nın ilk katmanı girdi katmanıdır. Bu katman dışardan aldığı bilgileri toplamakla görevlidir. Ortada bulunan katman gizli katman olarak bilinmektedir. YSA giren bilgileri işleyerek çıktı katmanına iletir. YSA'da gizli katmana sahip olmak zorunluluğu olmadığı gibi birden fazla gizli katmana da sahip olabilir. Girdi katmanı verilerin ağa girişinden sorumlu olması ve hesaplama yapmaması nedeniyle niceliksel olarak katman sayısına dahil edilmemektedir. Çıktı katmanı, girdi katmanında işlenerek elde edilen veri seti için çıktı üretmekle sorumludur (MacKay, 2003; Yıldız, 1999).

Bir sinir hücresi beş elemandan oluşmaktadır. Bunlar da girdi, ağırlık, toplama fonksiyonu, aktivasyon fonksiyonu ve çıktıdır.



Şekil 3.2. Bir nöron modeli (Gurney, 1996).

Biyolojik sinir ağları ve işleme elemanlarının benzerlikleri aşağıdaki çizelgede verilmiştir.

Çizelge 3.1. Nöronlar ve İşleme Elemanları (PE)'nin Benzerlikleri (Flores, 2011).

NÖRONLAR	GİRDİLER
Sinapslar	Ağırlıklar
Dendritler	Toplama Fonksiyonu
Hücre Gövdesi	Aktivasyon Fonksiyonu
Akson	Çıktı
Eşik Değeri	Yan Değer(Bias)

3.2.1. Girdiler

Dış dünyadan ya da herhangi bir sinir hücresinden gelen verileri ağa dahil etmekle görevlidir. Bu veriler ağı eğitmek için kullanılır.

3.2.2. Ağırlıklar

Ağırlıklar sinir hücresine giren bilginin hangi oranda işlemde kullanılacağını göstermektedir. Ağırlıkların boyutu o ağırlığın önem derecesini belirlememektedir. Hücreler arasındaki iletişimi sağlayan her bir bağlantının farklı ağırlık değeri bulunmaktadır. Bu sayede her girdi üzerinde ağırlıkların etkisi olmuş olur. Ağırlıklar sabit ya da değişken olabilmektedir (Baş, 2006).

3.2.3. Toplama Fonksiyonu

Toplama fonksiyonu, hücre tarafından alınan verinin net girdisini hesaplayan fonksiyondur. Her problem için kullanılan belirli bir toplama fonksiyonu yoktur. En iyi toplama fonksiyonu genellikle deneme yanılma yöntemiyle bulunmaktadır. Ağdaki tüm işlemciler aynı toplama fonksiyonuna sahip olmak zorunda değildir. Yapay sinir ağlarında toplama fonksiyonu seçimi tasarımcının iradesine bağlıdır. Yani istenirse farklı toplama fonksiyonunu istenirse de aynı toplama fonksiyonu tercih edebilir (Öztemel, 2012).

Bazı problemler toplama fonksiyonunu nasıl kullanacaklarını kendileri belirlerler. Daha karışık toplama fonksiyonları kullanıldığı durumlar da olmaktadır. Bu fonksiyonlar Çizelge 3.2.'de verilmektedir.

Çizelge 3.2. Toplama Fonksiyonları ve Özellikleri (Öztemel, 2003).

Toplama Fonksiyonu	Açıklama
Çarpım Net Girdi (U) = $\prod_{i=1}^n x_i w_i$	Net girdiyi hesaplamak için girdi değeri ile girdi ağırlığının çarpımı alınır.
Maksimum (En Çok) Net Girdi(U) = $\max(x_i w_i)$, $i = 1, \dots, n$	Girdi değerleri kendi ağırlıklarıyla çarpılır. En büyük değer (max) net girdi olarak kabul edilir.
Minimum (En Az) Net Girdi(U) = $\min(x_i w_i)$, $i = 1, \dots, n$	Girdi değerleri kendi ağırlıklarıyla çarpılır. En küçük değer(min) net girdi olarak kabul edilir.

<p>Çoğunluk</p> <p>Net Girdi(U) = $\sum_{i=1}^n \text{sgn}(x_i w_i)$</p>	<p>n adet girdi ve ağırlıklarıyla çarpımı hesaplanır. Negatif olanlar ile pozitif olanların çarpımı bulunur. Bunlardan büyük olan net girdi olarak alınır.</p>
<p>Kümülatif Toplam</p> <p>Net Girdi(U)= Net(eski) + $\sum_{i=1}^n x_i w_i$</p>	<p>Hücreye gelen bilgiler ağırlıklı olarak toplanır ve daha önce elde edilen bilgilerle toplanarak hücrenin net girdisi bulunur.</p>

3.2.4. Aktivasyon (Transfer) Fonksiyonu

Literatürde henüz gelişme göstermemesi nedeniyle Aktivasyon (Transfer) Fonksiyonu birçok sinir ağı yapısında kullanılmamaktadır. Bu fonksiyon toplama fonksiyonundan almış olduğu bilginin üzerinde işlemler yaparak çıktıya iletilmesini sağlar. Aktivasyon fonksiyonu, zamana bağlı olarak değişkenlik gösteren toplama fonksiyonu çıktısının değişmesini sağlamaktadır.

Aktivasyon fonksiyonu, sinir ağları üzerindeki nöronların girdilerden almış oldukları sinyalleri bir fonksiyon aracılığıyla dönüştürerek çıktı oluşmasını sağlamaktadır. Dönüştürme sonucu elde edilen değer eşik değerinden yüksekse çıktı değeri elde edilmiş olur. Dönüştürme işleminin yapılmasını sağlayan fonksiyona “Transfer Fonksiyonu” denilmektedir (Diler, 2003).

Sinir ağının yapısının her bir bölümünde aynı aktivasyon fonksiyonu kullanılmaktadır. Matematiksel olarak henüz belirli bir aktivasyon fonksiyonu bulunmadığı için en iyi fonksiyona deneme yanılma yöntemiyle tasarımcı karar vermektedir. En çok kullanılan aktivasyon fonksiyonları aşağıda verilmiştir.

1. Eşik Fonksiyonu
2. Doğrusal (Lineer) Fonksiyon
3. Basamak (Step) Fonksiyon
4. Sigmoid Fonksiyon
5. Hiperbolik Tanjant Fonksiyon

6. Gaussian Fonksiyon

Bu fonksiyonlar arasında en yaygın kullanılan aktivasyon fonksiyonu sigmoid fonksiyonudur.

Eşik Fonksiyonu: Bu fonksiyonun en önemli özelliği tüm girdi değerine karşılık sadece iki çeşit çıktı üretmesidir. Eğer girdi değeri, sapma değerini “ Θ ” aşarsa çıktı olarak α , aksi takdirde β sabit değerini alır. Bu fonksiyonun matematiksel ifadesi,

$$F(\text{net}) = \begin{cases} \alpha & \text{eğer } \text{net} \geq \Theta \text{ ise} \\ \beta & \text{eğer } \text{net} \leq \Theta \text{ ise} \end{cases} \quad (3.1)$$

Doğrusal (Lineer) Fonksiyon: Gelen girdiler olduğu gibi hücrenin çıktısı olarak kabul edilir.

$$F(\text{net}) = \text{net} \quad (3.2)$$

Basamak (Step) Fonksiyon: Gelen net girdi değerinin belirlenen bir eşik değerinin altında veya üstünde olmasına göre hücrenin çıktısı 1 veya 0 değerini alır.

$$F(\text{net}) = \begin{cases} 1 & \text{if } \text{net} > \text{Eşik Değeri} \\ 0 & \text{if } \text{net} \leq \text{Eşik Değeri} \end{cases} \quad (3.3)$$

Sigmoid Fonksiyonu: Uygulamada en çok tercih edilen fonksiyonlardan birisi sigmoid aktivasyon fonksiyonudur. Sürekli, kolay türevlenebilir ve doğrusal olmayan yapıya sahip olan sigmoid fonksiyonu YSA ile çözülen problemlerde en çok tercih edilen fonksiyon türüdür. Türevlenebilir olması nedeniyle geri yayılım algoritmalarında da sıklıkla tercih edilmektedir. Sigmoid fonksiyonu girdinin her bir değeri için 0-1 arasında çıktı üretmektedir. Bu fonksiyonun matematiksel gösterimi Eşitlik 3.4.’ de gösterildiği gibidir.

$$f(\text{net}) = \frac{1}{1+e^{-\text{net}}}, \quad 0 \leq f(\text{net}) \leq 1 \quad (3.4)$$

Hiperbolik Tanjant Fonksiyonu: Bu fonksiyon türü sigmoid fonksiyon gibi çok tercih edilmektedir. Sigmoid fonksiyonun başka bir türüdür. Çift kutuplu fonksiyon olarak da adlandırılmaktadır. Sigmoid fonksiyonundan farklı olarak çıktı değerleri 1 ile -1 arasında

değer almaktadır. Hiperbolik tanjant fonksiyonun matematiksel gösterimi Eşitlik 3.5.'da gösterilmektedir.

$$F(\text{net}) = \frac{e^{\text{net}} - e^{-\text{net}}}{e^{\text{net}} + e^{-\text{net}}} \quad (3.5)$$

3.2.5. Çıktı

Hücrenin çıktı değerini aktivasyon fonksiyonundan çıkan değer oluşturmaktadır. Bu değer sinir ağının dışına verilebileceği gibi girdi olarak kullanılmak için tekrardan sinir ağının içine de verilebilir.

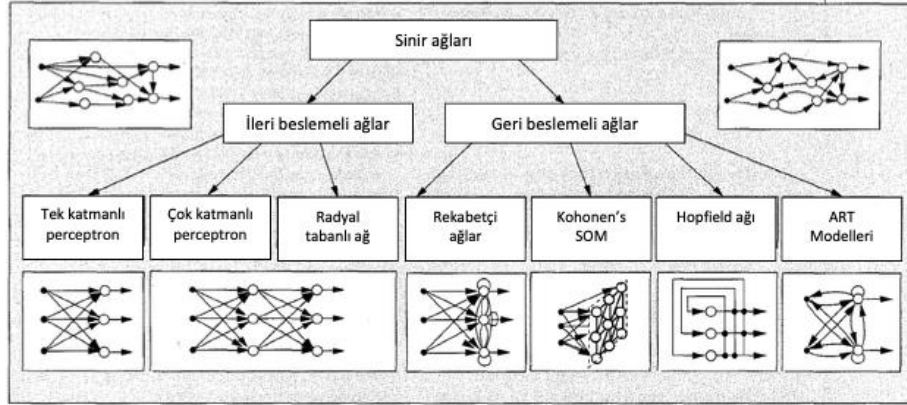
4. YAPAY SİNİR AĞLARININ SINIFLANDIRILMASI VE ÖĞRENME ALGORİTMALARI

4.1.YSA'nın Sınıflandırılması

YSA'nın yapısı topolojisi, bağlantı yapıları ve katman sayısı olacak şekilde üç başlık altında incelenmektedir. Bu kriterlere bakılarak yapay sinir ağlarının sınıflara ayırabilmek mümkün olmuştur. Bu bölümde detaylı bir şekilde yapay sinir ağlarının sınıflandırılması ve öğrenme metotları anlatılacaktır.

4.1.1. YSA'nın Yapısına (Topolojilerine) Göre Sınıflandırılması

Sinir ağının yapısı ağın performansı üzerinde oldukça önemli bir rol oynamaktadır. Nöronların sıralanış ve girdi elemanlarının birbirleriyle bağlanma şekli ağın genel yapısını belirlemektedir. Sinir ağları yapılarına göre ileri ve geri beslemeli olacak şekilde ikiye ayrılmaktadır (Baş, 2006).




Şekil 4.1. İleri-Geri Beslemeli Ağ Mimarisinin Bir Taksonomisi (Jain ve Mao, 1996).

4.1.1.1.İleri Beslemeli Ağlar

Yapılarına göre sınıflandırıldığında ileri beslemeli sinir ağları, oluşturulmuş ilk sinir ağı modelidir. YSA'nın en sade biçimini oluşturmaktadır. Bu YSA türünde nöronlar katmanlara ayrılmaktadırlar. Ağa giren veri girdi katmanından çıktı katmanına doğru tek yönlü olacak şekilde ilerlemektedir (Yadav vd., 2015).

Sinyaller girdi katmanından çıktı katmanına tek yönlü olarak hareket ederler. Ağ üzerinde herhangi bir geri bağlantı olmadığı için önceki çıktı değerleri ve transfer fonksiyonu hafızada tutulmaz (Kasabov, 1996). İleri beslemeli ağların örnekleri arasında, çok katmanlı algılayıcı (MLP) (Rumelhart ve McClelland, 1986), öğrenme vektörü kantifikasyonu (LVQ) ağı (Kohonen, 1989) ve veri taşıma grup yöntemi (GMDH) ağı (Hecht- Nielsen, 1990) bulunmaktadır.




Şekil 4.2. İleri Beslemeli Çok Katmanlı Yapay Sinir Ağı Modeli (Öztemel, 2003).

Şekil 4.2.'de ileri beslemeli çok katmanlı sinir ağı modeli görülmektedir. Sinir ağına örnekler ve bu örneklerden elde edilmek istenen beklenen çıktılar verilmektedir. Sinir ağı almış olduğu bu örneklerden bir çözüm uzayı oluşturmaktadır. Oluşan çözüm uzayından ileride çözülmesi istenecek problemler için sonuçlar elde edebilmektedir (Öztemel, 2003).

4.1.1.2.Geri Beslemeli Ağlar

Yinelemeli (recurrent) ağlar olarak da adlandırılmaktadırlar. Geri beslemeli sinir ağlarında çıktıdan girdiye doğru geri dönen bağlantılar olabilir. Böylelikle girdiler çift yönlü bir şekilde aktarım sağlamış olur. Tekrar eden ağın yapısı sinir ağının bir hafızaya sahip olduğunu gösterir. Bu durum sadece işlem görmekte olan girdilere değil, işlem gören önceki girdilerin de çözümünde oldukça fayda sağlamaktadır (Yadav vd., 2015).

Geri beslemeli ađlar dinamik yapıları sayesinde yüksek bir performans sergilemektedirler. Fakat ađ yapılarının belirlenmesi zor olduđu için denge noktasına ulařılana kadar ađa sürekli yeni girdiler göndermek gerekmektedir. Geri beslemeli yapay sinir ađları genellikle ölçülebilmesi zor girişleri olan dinamik yapıya sahip sistemlerin modellenebilmesi için kullanılmıştır. Şekil 4.3.'de geri beslemeli bir YSA yapısı gösterilmektedir.



Şekil 4.3. Geri Beslemeli Yapay Sinir Ađı Modeli (Diler, 2003).

Geri beslemeli YSA' lar ileri beslemeli YSA' lara göre daha dinamik yapılara sahip olmalarına rağmen ileri beslemeli ađlar uygulamada daha çok kullanılmaktadır. Bu ađların birden fazla deđişik ve tutarsız yapıya sahip olması nedeniyle eğitim aşamasında zorlanılmaktadır (Zhang, 2003). Ayrıca geri beslemeli ađların eğitim aşaması çok uzun sürede tamamlanmaktadır. Eğitim kümesine dahil olan veri sayısı arttıkça bu sürenin daha da uzadığını söyleyebilir (Gately, 1996).

4.1.2. YSA'nın Öğrenme Algoritmalarına Göre Sınıflandırılması

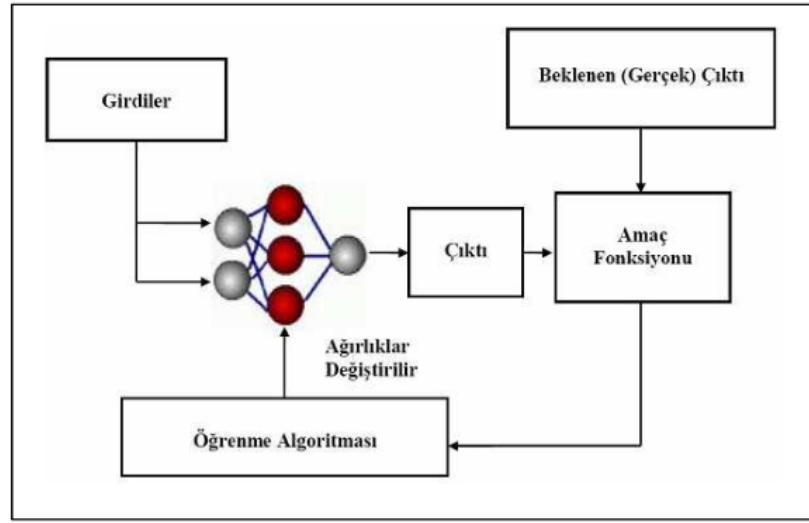
YSA davranışları yeni bir ortama girdiklerinde ortama uyum sağlayabilmek için deđişkenlik gösterirler. Bunun temel sebebi sinir ađındaki ađırlıklarda oluşan oynamalardır. Ađırlıklardaki bu deđişiklere sinir ađında öğrenme adı verilmektedir. 3 adet öğrenme türü bulunmaktadır (Fyfe, 2000). Bunlar;

- Denetimli Öğrenme
- Denetimsiz Öğrenme
- Takviyeli Öğrenme

4.1.2.1. Denetimli Öğrenme

Sinir ağlarının eğitilmesinde tercih edilen en yaygın yöntemdir. Sinir ağının eğitimine örnek oluşturabilmesi için ağa girdi ve istenilen çıktı değerlerini oluşturan bir veri seti verilir. Elde ettiğimiz çıktı ile elde edilmek istenen çıktı değeri kıyaslanır. Bu çıktılar arasındaki fark hata olarak kabul edilir. Bu yöntem ile oluşabilecek hataları minimize etmek amaçlanmaktadır. Bu nedenle çıktılar arasında yakın değerler üretebilmek için sinir ağına rasgele verilen ağırlık değerleri kendi arasında düzenlenebilir. Girdilerin ağırlık değerleri sürekli değiştirilerek en iyi performansı sağlayacak model oluşana kadar işleme devam edilir.

Bu modelde hataların hesaplanabilmesi için performans ölçütü Ortalama Mutlak Hata (OMH) ve Hata Kareleri Ortalamasının Karekökü (HKOK) kullanılır. Bu sayede gerçek çıktılar ile tahmin edilen çıktılar arasındaki hataları kıyaslanabilir ve gerçek değerlere en yakın değerler bulunmuş olur (Haykin, 1999).



Şekil 4.4. Danışmanlı Öğrenme Algoritmalarının İşleyişi (Hamzaçebi, 2005).

4.1.2.2. Denetimsiz Öğrenme

Bu yöntemde ağa herhangi bir örnek girdi ve istenilen çıktı verisi verilmemektedir. Girdilere göre ağ verileri sınıflandırır ve ağırlık değerleri atanır. Sinir ağı kendi kurallarına göre bir model oluşturur. İşlemlerin sonucunda ağın ürettiği çıktıları karşılaştıracağı bir danışmana gerek olmamaktadır (Şen, 2004).

4.1.2.3.Takviyeli Öğrenme

Bu yöntemde ağı yönlendiren bir danışman bulunmaktadır. İstenilen çıktılarının yerine ağı çıktılarının ne olacağı konusunda ilgilendirilir. Bu yönüyle denetimli öğrenme yöntemine benzemektedir. Ağı yapmış olduğu işlemler sonucunda doğru ya da yanlış olup olmadığı konusunda yardımcı olur. Ağ bu yönlendirmelere göre model üzerinde yeniden düzenlemeler yapabilir. Ağı öğrenme süreci bir danışman yardımıyla devam eder. Böylelikle model hem öğrenme sürecini devam ettirir hem de çıktı üretmeyi sürdürür (Öztemel, 2003).

4.1.3. YSA'nın Uygulama Alanlarına Göre Sınıflandırılması

YSA uygulama alanlarına göre; çevrimiçi (online) öğrenme ve çevrimdışı (offline) öğrenme olmak üzere ikiye ayrılmaktadır.

4.1.3.1.Çevrimiçi (online) Öğrenme

Çevrimiçi öğrenmeye göre çalışan sistemler normal zamandaki işleyişine devam ederken, diğer bir yanda da öğrenme işlemini sürdürmektedir. Eğer değişkenler her bir verinin sunulmasından sonra güncelleştirilirse, çevrimiçi öğrenme örneği elde edilmiş olur (Öztemel, 2012).

4.1.3.2.Çevrimdışı (offline) Öğrenme

Çevrimdışı öğrenmeye göre çalışan sistemler kullanılmaya başlanmadan önce daha önceki örnekler üzerinden eğitim almaktadırlar. Sistemler eğitimi tamandıktan sonra gerçek hayatta kullanıma alındığında artık öğrenme işlemi gerçekleşmemektedir. Eğitim tamandıktan sonra sistem tekrar kullanılabilir hale gelmektedir. Bu tip öğrenme şekline örnek olarak "*Delta Öğrenme Kuralı*" verilebilir (Öztemel, 2012).

4.2.Yapay Sinir Ağlarında Temel Öğrenme Kuralları

Yapay sinir ağına topolojik yapının yanında ağı eğitimi ve öğrenme süreci de büyük bir önem teşkil etmektedir. Öğrenme, sinir ağındaki tüm nöronların gerçekleştirdiği ortak bir süreçtir ve belli bir eğitim sonucunda gerçekleşir. Ağı eğitimi sürecinde doğru yöntem ve fonksiyonların kullanılması da çok önemlidir. Temel öğrenme kuralları 4 başlık altında incelenir.

Hebb Kuralı: 1949 yılında biyolojik bir temele bağlı olarak geliştirilen Hebb kuralı, en yaygın öğrenme kuralıdır. Bu kuralın tanımı “The Organization of Behavior” adlı kitapta yer almaktadır. Bütün öğrenme algoritmalarının temeli Hebb kuralına dayanmaktadır. Günümüzde en çok bilinen hata geri yayılım algoritmasının temelinde bile bu kural yatmaktadır (Öztemel, 2012).

Hopfield Kuralı: John Hopfield tarafından ortaya atılmıştır ve Hebb kuralına benzemektedir. Eğer beklenen çıktı ve girdilerin her ikisi aktif veya her ikisi pasif ise öğrenme katsayısı tarafından bağlantı ağırlığı kuvvetlendirilir. Diğer durumlarda ise zayıflatılır.

Delta Kuralı: 1960 yılında Windrow ve Hoff tarafından ortaya atılmıştır. Hebb kuralına benzerlik göstermektedir fakat daha gelişmiş halidir. Bu kuralın amacı toplam hatayı minimize etmektir. Yani girdi verileri işlendikten sonra elde edilen çıktı ve istenilen çıktı arasındaki farkların karelerinin toplam değerlerinin minimum yapılması amaçlanmaktadır. Hata sıfır değeri çıkıyor ise ağırlıklar üzerinde herhangi bir değişiklik yapmadan eğitimi bitirebilir (Öztemel, 2006).

Bu kuralda ki en önemli nokta, sinir ağına giren veri setinin rastgele bir şekilde dizilmiş olması tercih edilir. Aksi takdirde elimizdeki eğitim setinin düzgün bir şekilde dizilmiş olması ağın öğrenmesini ve doğru sonuca ulaşmayı güçleştirmektedir (Bayır, 2006).

Kohonen Kuralı: 1982 yılında Teuvo Kohonen tarafından biyolojik sistemlerinin öğrenme modelinden örnek alınarak geliştirilen bu kural “Yarışmacı Öğrenme Kuralı” olarak da bilinmektedir. Bu kuralda sinir ağının nöronları kendi aralarında ağırlıklarını değiştirmek için yarışlar. Hebb kuralından farkı ise, tek seferde sadece bir işlemci elemanın, yani kazanan nöronun bağlantı ağırlıklarının değiştirilmesidir (Bayır, 2006).


4.3.Yapay Sinir Ağı Modelleri

Yapay sinir ağları katman sayılarına göre tek katmanlı YSA ve çok katmanlı YSA olmak üzere ikiye ayrılmaktadır.

4.3.1. Tek Katmanlı YSA

Bu model sadece girdi ve çıktı katmanından oluşan en basit ağ modellerinden birisidir. Bu modelde bir veya birden fazla girdi olabilirken sadece bir adet çıktı bulunmaktadır. Çıktı fonksiyonu doğrusal bir fonksiyon olma özelliğine sahiptir. Bu fonksiyon 1 veya -1 değerlerini alabilmektedir. Bu modelde bilgi girdiden çıktıya doğru ilerler yani ileri beslemeli bir ağ özelliğine sahiptir. Gizli katmanı bulunmaması nedeniyle eğriselliği sağlayamamaktadır. Bu nedenle genellikle doğrusal olan modeller için kullanılırlar. Her bağlantı bir ağırlığa sahiptir ve çıktı birimi tüm girdi birimleriyle bağlantılı durumdadır. En basit haliyle tek katmanlı YSA modeli iki girdi ve bir çıktıya sahip olan ağıdır.

Tek katmanlı YSA' da ağın çıktısının sıfır olmasını önleyen bir eşik değeri (Θ)bulunmaktadır. Eşik değerinin girdisi daima +1'dir. Şekil 4.5.'de tek katmanlı YSA modeli verilmektedir.



Şekil 4.5. Tek Katmanlı Bir Yapay Sinir Ağı Modeli.

Sinir ağının çıktı değeri, ağırlıklandırılmış girdi değerleri ile eşik değerlerinin toplanması ve bu toplamın aktivasyon fonksiyonundan geçirilmesi sonucunda elde edilir. Bu işlemin matematiksel formülü şu şekildedir:


$$Y = f \left(\sum_{i=1}^m w_i x_i + \Theta \right) \quad (4.1)$$

Tek katmanlı yapay sinir ağı modellerinin en önemlileri Basit Algılayıcı Modeli, Adaptif Doğrusal Eleman ve Çoklu Adaptif Doğrusal Eleman' dır (Bayramoğlu, 2007).

4.3.1.1. Basit Algılayıcı Modeli (Perceptron Modeli):

1959 yılında Rosenblatt tarafından bulunmuştur. Modelleri doğru sınıflandırabilmek için sınıfların düzlemsel olarak ayrılması gerektiği ileri sürülmüştür. Basit algılayıcı modeli, miktarına bağlı olarak bir arada bulunan sinir hücrelerinin sınıflandırma problemini çözebilmektedirler (Nygren, 2004, Minsky ve Papert, 1969).

Bu modelde birden fazla girdi kullanarak tek bir çıktı elde etmek amaçlanmaktadır. Çıktı değeri bir ya da sıfırdan oluşan mantıksal bir değerdir ve çıktı değerini hesaplanmasında eşik değer fonksiyonunun yararlanılmaktadır.



Şekil 4.6. Basit Algılayıcı Modeli.

Basit algılayıcılarda girdiler işlem elemanlarına gösterilir ve her girdi sonucunda oluşan çıktı değeri de ağa gösterilir. Bu işlemin sonucunda öğrenme kuralları uygulanarak ağın çıktısı elde edilir. Ağın çıktısı ve istenilen çıktı birbirinden farklı ise eşik değer ve ağırlık değerleri üzerinde oynamalar yapılabilir. Bu oynamaların hangi oranda olacağını öğrenme kuralları belirlemektedir.

4.3.1.2. ADALINE /MADALINE Modeli

1959 yılında Widrow ve Hoff tarafından ortaya atılmış bir modellerdir. ADALINE modeli uyabilen doğrusal elemanlar olarak tanımlanmaktayken, MADALINE modeli ise çoklu uyabilen doğrusal elemanlar olarak tanımlanır (Anderson ve McNeill ,1992).

ADALINE modeli en küçük kareler ortalaması (MSE: HKO) yöntemine dayanmaktadır. Ağda bulunan bağlantı ağırlıkları hataları minimum yapabilmek için Delta Kuralı ile belirlenir. Öğrenme kuralına Delta Kuralı da denmektedir. ADALINE 'in yapısı Şekil 4.6.'da gösterilen basit algılayıcı modeline (Perceptron) benzemektedir. Aralarındaki fark ise öğrenme kuralındadır (Öztemel, 2003).

ADALINE modelinde ağıın çıktısını basamak aktivasyon fonksiyonu üretmektedir. Çıktı değeri 0'dan küçük ise çıktı -1, büyük ise +1 değerini alır. Bu modelde rasgele bir t anında hatayı azaltmak için kullanılan matematiksel formül Eşitlik 4.2.'de verilmiştir.

$$w_i(t)=w_i(t-1)+nEx_i \quad (4.2)$$

$w_i(t)$: ağırlığın t zamanındaki yeni değeri

$w_i(t-1)$: ağırlığın değişmeden önceki değeri

n: öğrenme katsayısı

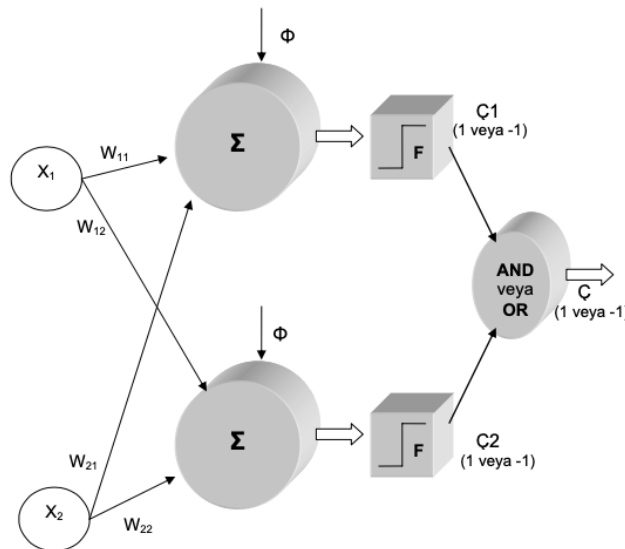
E: beklenen değer

x_i : girdi değeri

Eşik değeri (θ) de yine rasgele bir t zamanı içerisinde değiştirilerek istenilen eşik değeri hesaplanmaktadır. Bunun matematiksel gösterimi Eşitlik 4.3.'de verilmiştir.

$$\Phi_i(t)=\Phi_i(t-1)+nE \quad (4.3)$$

Birden fazla ADALINE ünitesinin bir araya gelmesi ile MADALINE ağıları oluşmaktadır. İki katmandan oluşan MADALINE ünitesinin her katmanında farklı sayıda ADALINE ünitesi bulunmaktadır. 1 ve -1 olarak gösterilen çıktı değerlerinin her biri bir adet sınıfı göstermektedir. Şekil 4.7.' de iki ADALINE ünitesinden oluşan bir MADALINE gösterilmiştir (Baş, 2006).



Şekil 4.7. İki ADALINE Ağından Oluşan Bir MADALINE Ağı.

4.3.2. Çok Katmanlı YSA

Çok katmanlı YSA'nın tek katmanlı YSA' dan farkı bir ya da birden fazla gizli katmana sahip olmasıdır (Fausett, 1994). Gizli katmanda işlem gören veriler doğrusal olmayan bir yapıya dönüştürülebilmektedir (Smith, 2002).

Çok katmanlı YSA'ların eğitiminin daha zor olmasına rağmen karmaşık birçok problemin çözümünde daha başarılıdır. Bunun nedeni tek katmanlı YSA modellerinin problemin çözümünde yetersiz kalmasıdır (Fausett, 1994). Çok katmanlı YSA'ya örnek olarak; Learning Vector Quantization Modeli ve Çok Katmanlı Algılayıcı (Multi Layer Perceptron- MLP) Modeli verilebilir (Bayramoğlu, 2007).

4.3.2.1.Çok Katmanlı Algılayıcılar (Multi Layer Perceptron- MLP)

Bir önceki bölümde anlatılan modeller doğrusal olan problemlere karşı bir çözüm üretebilmektedirler ve doğrusal olmayan problemlerin çözümünde zorlanmaktadırlar. Bu doğrultuda çok katmanlı algılayıcıları, doğrusal olmayan problemleri çözebilmek için geliştirilmiştir ve günümüzde yaygın olarak kullanılan bir sinir ağı modelidir. Bu modelde kullanılan öğrenme algoritması nedeniyle geri yayılım ağı olarak da bilinmektedir.

Çok katmanlı algılayıcılar yapay sinir ağlarına olan ilginin tekrardan artmasını sağlamıştır. Önce akademik çevrede ilgi görmeye başlamış, sonrasında mühendislik alanında da tüm problemlere çözüm üreterek endüstriyel alanda da yaygın bir şekilde tercih edilmeye başlanmıştır.

Bu modelde öğrenme kuralı olarak Genelleştirilmiş Delta Kuralı (Generalised Delta Rule) kullanılmaktadır. Bu kural en küçük kareler yöntemine dayalı bir kuraldır. ADALINE ve tek katmanlı perceptron modellerinin öğrenme şeklinin daha gelişmiş ve Delta Kuralının (Delta Rule) da genelleştirilmiş halidir. Genelleştirilmiş Delta Kuralı, denetimli öğrenme kuralı olarak bilinmektedir. Bu kuralda ağın istenen çıktısı ile ürettiği çıktı arasındaki hatayı minimum yapmak amaçlanmaktadır.


Bir MLP modeli giriş, ara ve çıkış katmanı olacak şekilde üç katmandan oluşmaktadır. Her katmanda bir veya daha fazla işlem elemanı bulunmaktadır ve bunlar üst katmanda bulunan işlem elemanlarının hepsiyle bağlıdır. Bilginin sürekli olarak ileri olması nedeniyle ileri beslemeli ağlar olarak da bilinmektedir. MLP ağlarının giriş katmanında

veriye herhangi bir işlem yapılmaz. Problemin tipine göre giriş ve çıkış katmanında kullanılacak işlemci eleman sayısı belirlenir. Ara katmandaki işlemci eleman sayısı ise deneme-yanılma sayesinde bulunmaktadır (Sağıroğlu vd, 2004).

4.3.2.2.Öğrenme Vektör Nicelendirilmesi (Learning Vector Quantization)

Kohonen tarafından 1984 yılında ileri sürülen Learning Vector Quantization (LVQ) modelinin temel amacı n boyutlu bir vektörü daha düşük boyutlu vektörlerle gösterebilmektir. Çıktı katmanındaki vektör setine referans vektör adı verilir. Burada amaç, giriş vektörü ile çıkış vektörünün eşleşebilmesini sağlamaktır.

LVQ modeli de MLP modeli gibi üç katmandan meydana gelmektedir. Giriş katmanında veri üzerinde bir işlem yapılmamaktadır. İkinci katmanda Kohonen katmanı olarak da bilinen ara katman bulunmaktadır. Bu katmanda yer alan her birim bir referans vektörüne karşılık gelmektedir. Çıktı katmanı olan üçüncü katmanda ise girdi vektörünün sahip olduğu kategori belirlenmektedir (Baş, 2006).



Şekil 4.8. LVQ Ağının Topolojik Yapısı.

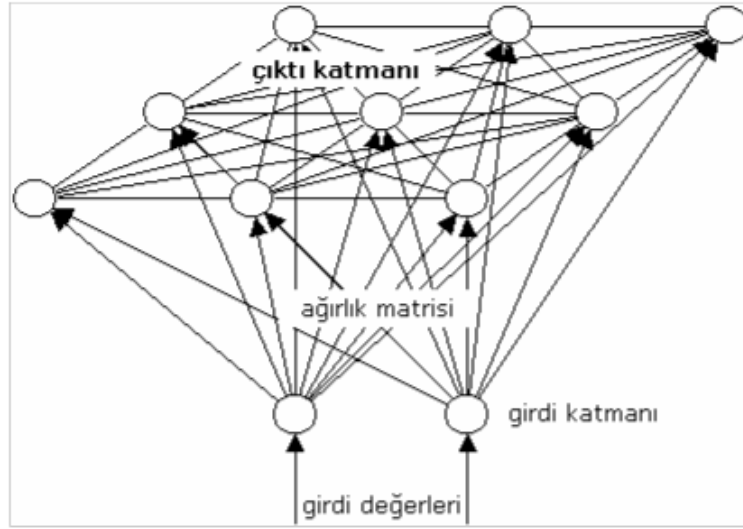
LVQ modelinde Kohonen' in öğrenme kuralı kullanılmaktadır. Bu modelin eğitimi sırasında girdi ve referans vektörü arasında bulunan en kısa mesafe aranmaktadır. Girdi bulunan en kısa mesafeli gruba dahil edilecektir. Ağın ağırlıkları değiştirilerek girdileri doğru sınıflara ayıracak referans vektörleri belirlenmektedir. Çıktı değerlerinin belirlenmesinde “*kazanan her şeyi alır (winner takes all)*” stratejisi uygulanır (Kröse ve van der Smagt, 1996).

4.3.3. Kohonen Ağı

1972 yılında Kohonen tarafından beyinde bulunan Neocortex tabakasında kullanılan duysal haritalardan ilham alınarak ileri sürülmüş bir modeldir. Self Organization Feature Map Network-Özörgütlemeli Özellik Haritası (SOM) olarak da adlandırılmaktadır.

Sınıflandırma problemlerinin çözümünde oldukça başarılı olan bir modeldir. Kohonen ağları eğitimleri sırasında bir danışmana ihtiyaç duymamaktadır. Bu nedenle denetimsiz gerçekleştirilen bir ağ modelidir (Oğuzlar, 2006).

Kohonen ağlarının kullanım amacı, girdi değişkeninde bulunan örüntüleri açığa çıkarmaktır. Çıktılar gözlemlendiğinde veriler gruplandırılmış bir şekilde elde edilmektedir. Bu ağlar bir girdi ve iki boyutlu Kohonen tabakasından meydana gelmektedir (Kiang, 2001).



Şekil 4.9. Kohonen Ağı (Fröhlich, 1997).

Kohonen ağında *yarışmacı öğrenme yöntemi* kullanılmaktadır. Kazanan elemanlar 1, diğer elemanlar ise 0 ile temsil edilmektedir.

4.3.4. ART (Uyarlanabilir Rezonans Teorisi-Adaptive Resonance Theory) Ağları

Uyarlanabilir Rezonans Teorisi (ART) ağları 1970'li yılların ortalarında Stephen Grossberg tarafından beyin fonksiyonlarını açıklamaya ilişkin araştırmalar sonucunda ortaya atılmıştır. Bu model 3 temel üzerine kurulmuştur. Bunlar:

- Normalizasyon: İnsanlarda bulunan biyolojik sistemler buldukları ortamlardaki değişimlere oldukça duyarlıdır ve aynı zamanda bu değişimlere adapte olabilmeye özelliklerine sahiptirler.
- Ayırıştırabilme: İnsanlar tarafından fark edilme olasılığı güç olan ayrıntıları ayırıştırabilme yeteneğidir.
- Ayrıntıların saklandığı kısa dönemli hafıza: Bilgilerin geçici bir süre saklandığı ve yeni bilgiler elde edilmesi durumunda eski bilgilerin yok olarak yeni bilgilerin saklanmaya devam edildiği yerdir (Baş, 2006).

Bu ağlar, genellikle F1 ve F2 olarak adlandırılan iki katmandan oluşmaktadır. F1 katmanı girdi değerlerinin özelliklerini, F2 katmanı ise kategorilere ayrılan sınıfları göstermektedir. F1 katmanından girdiler ağa alınırken F2 katmanında sınıflandırma işlemi yapılmaktadır.



Şekil 4.10. ART Ağlarının Yapısı (Kröse ve van der Smagt,1996).

4.3.5. Hopfield Ağı

Ünlü bir fizikçi olan John Hopfield tarafından 1982 yılında geliştirilen bir modeldir. Hopfield ağı, beyine benzer yönüyle belirli hafıza ve örüntüleri kaydeden bir yapısı bulunmaktadır. Basit bir yapıya sahip olması nedeni ile yapay sinir ağı problemlerinde sıklıkla tercih edilmektedir (Gülseçen, 1993).

Bu ağ hem tek katmanlı hem de geri beslemeli bir ağ yapısına sahiptir. Hopfield ağı genelde ikili (0,1) veya bipolar (1,-1) girişleri tercih etmektedir. İşlemci elemanları

birbirleriyle bağlantı halindedir. Bağlantılar iki yönlüdür yani iki tarafta da bilgi akışı sürmektedir. Bu iki yönlü bilgi akışına dahil olan her bir bağlantı için hesaplanan ağırlık değerleri bulunmaktadır. Hopfield ağına eğitimi bir adımda gerçekleşmektedir. Matematiksel gösterimi Eşitlik 4.4.'de gösterilmektedir.

$$w_{ij} = \begin{cases} \frac{1}{N} \sum_{c=1}^p x_i^c x_j^c & , i \neq j \\ 0 & , i = j \end{cases} \quad (4.4)$$

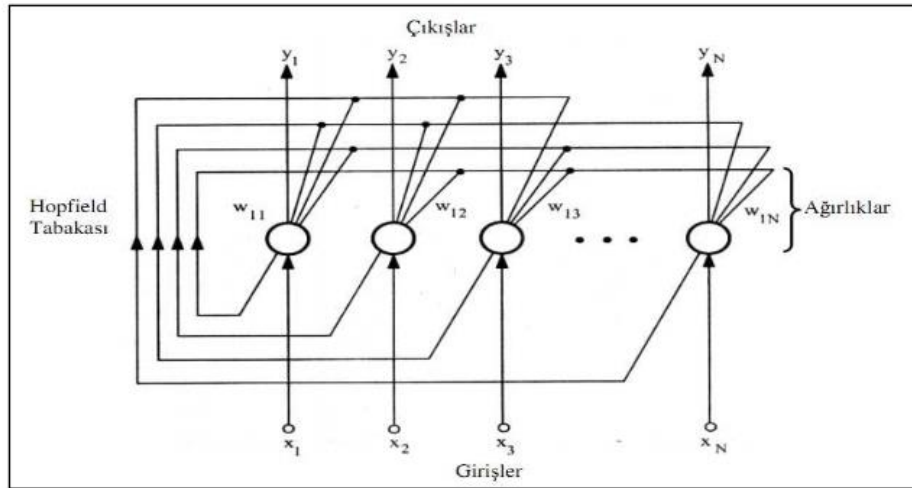
w_{ij} : i işlemci elemanından j işlemci elemanına olan bağlantı sayısı,

x_i^c : c sınıfı için eğitime giriş deseninin i. elemanı,

p: sınıf sayısı,

N: işlemci eleman sayısı.

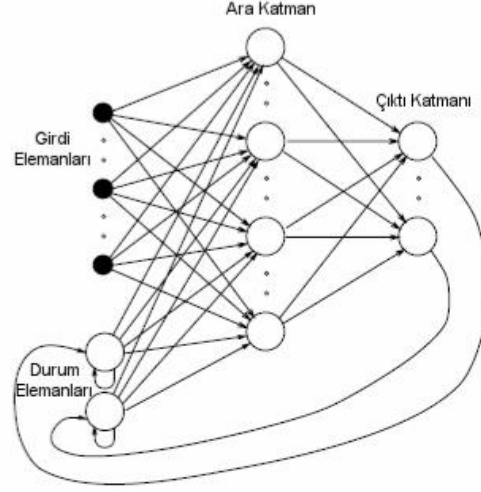
Eşitlik (4.4) denkleminde $w_{ij} = w_{ji}$ ve $w_{ii} = 0$ durumları ağına kararlılığını garantilemektedir.



Şekil 4.11. Hopfield Ağı (Sağiroğlu vd. 2003).

4.3.6. Jordan Ağı

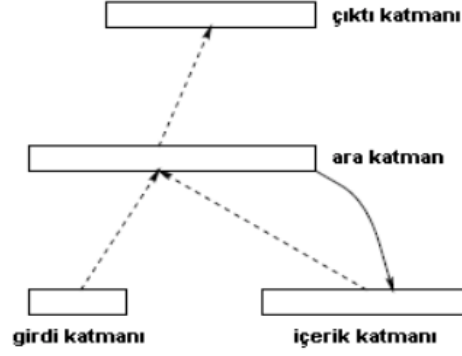
Bu model çok katmanlı geri beslemeli bir sinir ağı örneğidir. Çok katmanlı ağlar ile yapısal olarak benzerlik göstermektedir. Çok katmanlı ağlara ek olarak özel işlemci elemanlarına sahiptirler. Durum elemanları (state units) olarak da bilinen özel işlemci elemanlarının görevi çıktıdan almış oldukları aktivasyon değerlerini bir sonraki iterasyona girdi olarak taşımaktır (Baş, 2006).



Şekil 4.12. Jordan Ağı (Kröse ve van der Smagt,1996).

4.3.7. Elman Ağı

1990 yılında Elman tarafından ortaya atılan bir modeldir. Girdi, çıktı ve ara katmandan oluşmaktadır. Bu üç katmana ilaveten içerik katmanından (context layer) sahiptirler. İçerik katmanının görevi ara katmanda bulunan aktivasyon değerlerinin sonraki iterasyona taşınmasında rol oynamaktadır. Jordan ağları ile Elman ağları birbirlerine fazlasıyla benzemelerine rağmen temelde aralarında iki adet fark bulunmaktadır. Bu farklardan birincisi içerik elemanlarının kendileriyle bağlantılarının bulunmamasıdır. Diğeri ise geri besleme işlemi sonucunda aktivasyon değerini çıktı katmanı yerine ara katmandan almasıdır (Baş, 2006).



Şekil 4.13. Elman Ağı Yapısı (Kröse ve van der Smagt, 1996).

Şekil 4.14.’de Elman ağının yapısını görülmektedir. Bu ağda girdi ve çıktı dış dünyayla iletişim içerisindedir. Bilgi işleme yeteneği olmayan girdi katmanından ağa giren bilgiler ara katmanı iletilir. Çıktı katmanı işlenen bilgileri dış dünyaya iletir. Çıktı katmanı sadece kendisine iletilen bilgiyi işlemesi nedeniyle bilgi işleme fonksiyonlarının da doğrusal olduğu sonucu ortaya çıkmaktadır. Ara katmanlar hem doğrusal hem de doğrusal olmayan fonksiyonlara sahiptirler (Öztemel,2012).

4.4.YSA ile Modelleme

Öner (1998) tarafından sistemin en başarılı şekilde açıklanmasına “model”, modeli gerçekleştirme ve meydana getirme sürecini de “modelleme” olarak tanımlamıştır.

Doğru modelleme yapabilmek için kullanılan iki yaklaşım bulunmaktadır. Bunlar:

- Kümelendirilmiş parametre modellemesi
- Sistem tanımadır.

İlk yaklaşımda girdi-çıktı arasındaki ilişkiyi yeterince basitleştirerek yapılandırmak amaçlanır. Diğer yaklaşımda ise deneysel olarak elde edilmiş girdi-çıktı verilerinin matematiksel modeli kurulmaya amaçlanır.

Modelin elde edilebilmesi için gerekli olanlar,

1. Girdi-çıktı verisi,
2. Model adaylarının belirlenmesi,

3. Modelin seçim kriteridir.

Günümüzde her problem için geçerli olacak bir YSA modeli geliştirilememiştir. Bu nedenle en iyi çözümleri elde edebilmek için tüm faktörlerin dikkate alınması gerekmektedir.

- I. Verilerin basitleştirilerek yazılması ((0,1) aralığına dönüştürülmesi),
- II. Eğitim ve test verilerinin ayrıştırılması,
- III. Sinir ağının modelinin kurularak gizli katman ve çıktı sayısının belirlenmesi,
- IV. Aktivasyon fonksiyonunun seçilmesi,
- V. Performans ölçütünün hesaplanması,
- VI. YSA'nın eğitilmesi,
- VII. Uygulama.

Modelleme Adımının İşlem Basamakları

Girdi Nöron Sayısı

Girdi nöron sayısının belirlenmesinde bir kural olmaması nedeniyle deneme yanılma yöntemi ile bu sayı belirlenmektedir. Katmandaki nöron sayısı girdi veri sayısı ile eş değerdedir. Bu katmandaki veri işlem görmeden direk gizli katmana aktarılmaktadır.

Gizli Katman Sayısı

Bu katman verinin işlendiği katmandır. Bazı sinir ağlarında birden fazla gizli katman olabilir ve bu katman sayısı probleme göre değişkenlik gösterir. Problemde hiç gizli katman bulunmuyorsa girdiden çıktıya doğru doğrusal bir bağlantı vardır. Bu doğrusallık sonucunda girdinin hangi çıktıyla eşleştiği belirlenir. Sinir ağında birden fazla katman olması durumu çok karşılaşılan bir durum değildir. Katman sayısı ne kadar artarsa hem tasarım hem de problemin çözümü o kadar karmaşık bir hal almaktadır.

Gizli Katmandaki Nöron Sayısı

Modellemenin en önemli noktalarından birisi gizli katmanında kaç tane nörona sahip olacağını belirlemektedir. Modelin genelleştirilmesi ve doğru şekillendirilmesi gizli katmandaki nöron sayısına bağlı olarak ilerlemektedir. Gizli katmandaki nöron sayısı,

sinir ağının öğrenme sürecinde hafızasında fazla bilgi bulundurmakla beraber öğrenme işleminin de daha başarılı bir şekilde tamamlanmasını sağlamaktadır.

Çelebi ve Bayraktar (2008)'a göre gizli katmana ait nöron sayısının saptanmasında belli bir kural olmaması nedeniyle deneme-yanılma yöntemi sıklıkla kullanılmaktadır.

Gizli katman, girdi katmanından bulunan verileri işleyerek sıradaki katmana iletmekle görevlendirilmiştir. Bu işlem yapılırken katmanda olması gerektiğinden daha az nöron kullanılması hem çıktıların daha hassas olmasına hem de elde edilen verilerin verilen test kümesindeki verilerle eşleşmemesine neden olabilir. Normalde iki farklı nöron üzerine taşınacak veri aynı nöron üzerine taşınmış olur. Bu durum da verilerin daha karmaşık hale gelmesine neden olur.

Benzer şekilde gereğinden fazla nöron kullanılması durumunda da ağda yeni tip verilerin işlenmesinde zorluklar yaşanır. Daha farklı bir şekilde ifade edilirse, nöronların fazla olması durumunda her bir nöronu eğitecek yeterli eğitim kümesi olmayabilir. Karşılaşılacak başka bir problem ise, eğitim kümesi yeterli miktarda olsa bile verilerin geç öğrenmesi durumudur. Bu durumda da sinir hücresinin eğitimi çok daha uzun zamanda tamamlanmaktadır.

Çıktı Nöron Sayısı

Zaman serisi tahmin problemlerinde çıktı nöron sayısı ile tahmin döneminin uzunluğu eşit olacak şekilde alınır. Yani yapılacak olan çalışmalarda dönemlik tahmin süresi ile çıktı nöron sayısı eşit olarak alınabilir. Bu yöntem doğrudan öngörü yöntemi denilmektedir. Bir diğer alternatif yöntem ise iteratif öngörü yöntemidir. Bu öngörü yönteminde ilk adımda öngörü veri olarak kullanılır bu da bir sonraki öngörünün elde edilmesini sağlar. Kullanılacak olan öngörü yöntemlerinin hangisinin daha iyi olduğuyula alakalı belirlenmiş genel bir sonuç bulunmamaktadır (Günay vd., 2007).

Aktivasyon Fonksiyonu

Aktivasyon fonksiyonu, eşik fonksiyon veya sıkıştırma fonksiyonu olarak da bilinmektedir. Bu fonksiyon yapay sinir ağında bulunan nöronların çıktısının ağırlıklarını sınırlandırmak için kullanılır (Mandic ve Chambers, 2001). Belirlenen aktivasyon

fonksiyonu doğrusal değil ise eğim parametresinin de saptanması gerekir (Aladağ vd., 2007).

Normalleştirme İşlemi

Verilerin normalize edilme işlemi YSA’larda doğrusal olmama özelliğini sağlayan en önemli etkenlerden biridir. Bu işlem yapılarak hem kümülatif toplam değer daha düşük çıkmaktadır hem de veriler aşırı uç değerlerden kurtulmuş olmaktadır. Bu işlem sayesinde sinir ağı daha başarılı bir şekilde modellenmektedir. Sinir ağının modellenme aşamalarında normalize işleminin yapılması zorunludur fakat bu işlem sayesinde de verilerin gerçek değerleri korunamamaktadır.

Normalize ettiğimiz verilerimiz aktivasyon fonksiyonuna bağlı olarak (-1, +1) aralığında değerlere atanırlar.

$$\hat{x}_i = \frac{x_i - x_{\min}}{x_{\max} - x_{\min}} \quad i=1, \dots, N \quad (4.5)$$

Burada,

x_i = N sayıdaki veri kümesinde yer alan i.nci veri,

x_{\min} = N sayıdaki veri kümesinde yer alan minimum değere sahip veri,

x_{\max} = N sayıdaki veri kümesinde yer alan maksimum değere sahip veri,

\hat{x}_i = N sayıdaki veri kümesinde yer alan normalleştirilmiş i’ nci veriyi göstermektedir.

Eğitim ve Test Kümesi

YSA eğitiminde olması gereken en önemli noktalardan birisi eğitim kümesinin belirlenmesidir. Bu küme oluşturulurken az miktarda ve birbirinden bağımsız veri seçilmesi eğitimin sonucunu daha başarılı bir hale getirmektedir. Sinir ağının eğitimi bittikten sonra öğrenimini tamamlayıp tamamlamadığını kontrol etmeye ağın test edilmesi adı verilmektedir.

Ağın Eğitimi

Ağın eğitimi, problemin çözümüne ilişkin girdi ve çıktılar arasındaki bağlantıları öğrenip eşleştirme yapabilmesi için çok önemli adımdır. Ağın yeterince eğitilmesi daha önce karşılaşılmamış girdilere uygun çıktı üretmesini sağlamaktadır. Yapay sinir ağının bu özelliği genelleme kapasitesi olarak bilinmektedir. Bu kapasite ağın yapısı ile eğitim için uygulanan yineleme miktarına bağlıdır (Alkan, 2001).

“Ağın eğitilmesi”, katmalar arasındaki nöronların ağırlık değerlerinin belirlenmesi işlemine denmektedir. Rasgele olarak alınan bu ağırlık değerler kendilerine örnekler gösterildikçe kendilerini güncelleyerek problemin çözümünü elde etmeye çalışırlar. Sinir ağına giren girdiler ile bir sonuca ulaşılmış ise ağırlık değerleri saklanır.

Birden fazla gizli katmana sahip modeller için de YSA eğitim yöntemi uygulanabilmektedir. Ağın eğitimi sonucu beklenen çıktı ve hesaplanan çıktı arasındaki fark birbirine yaklaşmış ise sinir ağının öğrenme işlemi tamamlanmış olur.

Bu şekilde danışmanlı öğrenen sinir ağlarının eğitiminde hatanın geri yayılımı kullanılmaktadır. Bu yaklaşım ile gerçek çıktı ve hesaplanan çıktı arasındaki fark yani hata değeri geri yayılmaya başlayarak eğitimin her aşamasın da hatayı bir önceki katmana yayarak ağın ağırlık değerlerini güncelleştirir. Geri yayılım algoritmaları oldukça iyi sonuçlar veriyor olmasına rağmen eğitim süreçleri çok uzun süreler almaktadır. Bu nedenle eğitimin hızlı sonuçlanması gereken problemlerde uygun bir yöntem olmamaktadır.

Öğrenme Katsayısı

Öğrenme katsayısı, ağırlıklar üzerinde bulunan değişim miktarını belirlemektedir. Bu katsayının çok büyük olması ağırlık değerlerinin rasgele değiştirilmesine sebep olmakta ve eğer bu değer çok küçük olur ise problemin çözümüne ulaşmak uzun zaman almaktadır.

Momentum Katsayısı

Yapay sinir ağlarının öğrenme oranındaki belirli seviyedeki hızlanma momentum katsayısı sayesinde gerçekleşir. Bu katsayının çok küçük seçilmesi yerel çözümlerden

kurtulmayı zorlaştırmaktadır. Çok büyük seçilmesi ise net bir çözüme ulaşılmasını zorlaştırabilir. Algoritma dengede iken momentum kullanarak daha büyük bir öğrenme hızı elde edilebilir. Momentum katsayısı (γ), yerel çözümlere takılmayı engeller ve (0,1) arasında değerler almaktadır.

Eğitimin Durdurulması

Elde edilen hatanın belli bir değerin altına düşmesinden sonra eğitim tamamlanır. Diğer bir ifadeyle belirli sayıda iterasyondan sonrada eğitim durdurulur.

Ağın Test Edilmesi

YSA'nın aldığı eğitim test etmek amacıyla yapılan süreci kapsamaktadır. Ağın test aşamada ağa test kümesindeki verilerin kullanılarak öğrenme aşamasında görmediği verilerin uygulanması gerektiği belirtilmiştir (Öztemel, 2003).

Performans Ölçütleri

Sinir ağı modelinin verileri öğrenip öğrenmediğinin test edilmesi gerekmektedir. Bu sayede modelin uygulamada kullanıp kullanılamayacağı da belirlenir. Performans ölçütlerinde sıkça kullanılan performans ölçütleri yer almaktadır. Bu performans ölçütlerinden Hata Kareleri Toplamı (HKT) ve Hata Kareleri Ortalamalarının Karekökü (HKOK), Ortalama Mutlak Hata (OMH) ve Ortalama Mutlak Yüzde Hata (OMYH) kullanılmaktadır. Amaç bu değerleri minimum yapmaktır.

Çizelge 4.1. Performans Ölçütleri

Performans Ölçütü	Denklem
Hata Kareleri Toplamı (HKT)	$\frac{1}{T} \sum_{t=1}^T \varepsilon^2$
Hata Kareleri Ortalamasının Karekökü (HKOK)	$\sqrt{\sum \frac{\varepsilon_t^2}{T}}$
Ortalama Mutlak Hata (OMH)	$\frac{1}{T} \sum_{t=1}^T A_t - F_t $
Ortalama Mutlak Yüzde Hata (OMYH)	$\frac{100}{T} \sum_{t=1}^T \left \frac{A_t - F_t}{A_t} \right $
<i>t: zaman periyodu, T: zaman periyodlarının sayısı, A_t: t zaman periyodundaki tahmin edilen değişkenin gerçek değeri, F_t: t zaman periyodundaki tahmin, ε_t: t. dönem tahmin hatası</i>	

5. PORTFÖY OPTİMİZASYONU

5.1.Portföyün Tanımı

Portföy, kelime anlamı olarak “cüzdan” demektir. Menkul kıymetler açısından portföy, menkul kıymetlerden oluşan bir topluluğu ifade etmektedir. “Bir kişinin istikbalini tayin eden harcama kararlarının bütünü bir portföy olarak adlandırılır” (Sharpe, 1988).

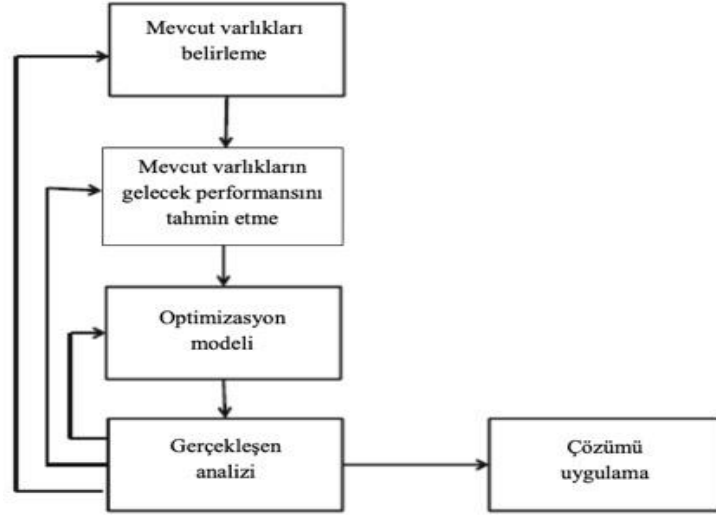
Günümüzde menkul kıymetlere yapılan yatırımlar belirli hedeflere ulaşılabilme için tercih edilmektedir. Portföyü oluşturan menkul kıymetler arasında belirli ilişkiler bulunmakta ve kıymetler arasındaki bu ilişkiler portföyün kendine özgü ve belirlenebilir özellikleri olan bir varlık olmasını sağlamaktadır.

Yapılan açıklamalar toparlanacak olur ise genel olarak, “Portföy, belirli amaçları gerçekleştirmek isteyen yatırımcıların, sahip olduğu, birbirleriyle ilişkisi olan ve kendine öz ölçülebilir nitelikleri olan yeni bir varlık” olarak tanımlanabilir (Ceylan ve Korkmaz, 1995).

Yatırımcılar portföy teorisine göre sadece bir adet menkul kıymete yatırım yapmayı tercih etmezler. Varlıklarını birden fazla menkul kıymet arasında bölüştürürler. Bunun amacı çeşitlendirmeyi artırarak riski azaltmaktır (Akgüç,1994).

5.2.Portföy Optimizasyonu

Portföyün ilk kez oluşturulduğu ve varlıkların satın alındığı ana yatırım zamanı denilmektedir. Oluşturulan mevcut portföyün yeniden gözden geçirildiği ve piyasaya göre yeniden düzenlemelerin yapıldığı zamanlar olabilir. Bu zamanlarda elimizde olan varlıklar satılabilir veya yeni varlıklar alınabilir. Bu tür işlemler ek maliyet getirmesine rağmen sabit veya değişken zaman aralıklarında uygulanabilmektedirler (Mansini vd., 2015)



Şekil 5.1. Portföy Optimizasyon Süreci (Mansini vd., 2015).

Yatırımcı portföyünün sabit kalacağı zamanı da hesaba katmaktadır. Bu süre çok uzun veya çok kısa olabilir. Önemli olan bu zamanın sonun elde edilen getiridir. Varlıkların gelecekteki performansı ile ilgili beklentilerin, hedef zaman olarak adlandırılan anda gerçekleşmesi beklenir. Bir portföyün yatırım süresinde oluşturulduğu ve hedef zamana kadar tutulduğu stratejiye alım ve satım stratejisi denir (Mansini vd., 2015).

5.3.Portföy Yönetimi

Gerçek ve tüzel kişiler, ekonomik şartlar altında sahip oldukları kıymetli evraklarını risk faktörünü de göz önünde bulundurarak olabildiğince artırmayı amaçlamaktadırlar. Portföyü ağırlıklı olarak hisse senedi, tahvil, bono gibi kıymetli evraklar oluşturmaktadır. Bu portföyün doğru bir şekilde yönetilmesiyle varlıkların getirisini artırılabilir.

5.4.Portföy ile İlgili Temel Kavramlar

Bu bölümde konunun daha net ve anlaşılabilir olması için sık kullanılan kavramlara yer verilecektir.

Borsa: Menkul kıymetlerin alım-satım işlemlerinin gerçekleştiği, fiyatlarının belirlendiği ve tüzel kişiliğe sahip olan kurumlardır. Bir ülkede borsanın varlığı özel teşebbüs aracılığıyla sanayileşmenin, şirketleşmenin ve halka açılmanın bir belirteçidir (Bolak, 1994). Diğer bir ifadeyle tabana yayılan sanayinin göstergesidir.

Bir ülkenin sosyal ve ekonomik gelişmişlik düzeyinin en belirgin göstergesi borsadır ve ülkeye pek çok avantaj sağlamaktadır. Bunlar, menkul kıymetlerin pazarlanabilirliğinin likidite sağlaması, ekonomiye kaynak sağlanması, ekonominin göstergesi olma işlevi, menkul kıymetlerle bilgilere kolay ulaşılması, sanayide yapısal değişikliği kolaylaştırma işlevi kazandırması şeklinde ifade edilebilir.

Menkul Kıymet: Menkul Kıymet, yatırım amacı ile sahip olunan kişiler arasında ortaklık veya alacaklık durumu yaratan, belli bir meblağı temsil eden, dönemsel olarak getiri elde edilen, Sermaye Piyasası Kurulundan izin çıkarılan kıymetli evraklardır (Üstünel, 2000).

Hisse Senedi: Bir anonim şirketin, birbirine eşit paylarından birini temsil eden, sahibine şirkete payı nispetinde ortaklık sağlayan kıymetli evraklardır. Hisse senedine yatırım yapan yatırımcılar, şirket karından pay alma, şirket yönetimine katılma, oy kullanma tasfiyeden pay alma, şirket faaliyetlerinden bilgilendirme ve rüçhan hakkına (sermaye artırımında öncelikli pay alma hakkı) sahiptirler (Üstünel, 2000).

Dönemlik Getiri: Hisse senedine yatırım yapanların kazançları, temettü (şirketin bir yatırım dönemi boyunca elde ettiği karın pay başına ödenen miktarı) ve hisse senedinin fiyat artışından oluşmaktadır. Yatırım yapılan dönem içerisinde temettü tahsilatı yapılmadığı varsayılırsa, hisse senedinin getirisi aşağıdaki şekilde bulunur:

$$R = \frac{F_{t+1} - F_t}{F_t} \quad (5.1)$$

Yukarıdaki formülde R hisse senedinin getirisini gösterirken, F_t t zamanındaki hisse senedinin fiyatını, F_{t+1} ise t+1 zamanındaki hisse senedinin fiyatını göstermektedir (Üstünel, 2000).

Arbitraj: Kıymetli maden, para veya menkul kıymet gibi finansal varlıkların aynı anda çeşitli piyasalarda farklı fiyatlardan işlem görmesinden yararlanarak elde edilen risksiz kazançtır. Arbitraj, aynı finansal varlığın düşük fiyatlı piyasadan satın alınıp, sonrasında yüksek fiyatlı piyasada satılarak risksiz kar elde edilmesi olarak açıklanmaktadır (Ceylan ve Korkmaz 1995).

Risk: Finansal açıdan risk, tahmin edilen getiri miktarının gerçek getiriden sapma olasılığıdır. Diğer bir ifadeyle beklenen getirinin, gerçekleşen getiriden sapma olasılığıdır. Sapma olasılığı yatırımın riskini oluşturmaktadır.

Risk Kaynakları: Risk kaynaklarını sistematik ve sistematik olmayan riskler oluşturmaktadır. Bu ayırım yatırımcının riski kontrol altına tutabilme durumuna göre değişkenlik göstermektedir. Sistematik risk, piyasada bulunan varlıkların tamamını etkilemektedir. Sistematik olmayan risk ise ilgilenilen varlığın sahip olduğu özelliklerinden kaynaklanan risktir. Menkul kıymetin toplam riski sistematik ve sistematik olmayan riskin toplamıyla bulunmaktadır. Toplam risk,

$$\sigma_i^2 = \beta_i^2 \sigma_m^2 + \sigma_e^2 \quad (5.2)$$

σ_i^2 = Yatırım yapılan menkul kıymetlerin toplam riski

β_i^2 = Menkul kıymetlerin riske karşı duyarlılığı

σ_m^2 = Sistematik risk

σ_e^2 = Menkul kıymetlerin sistematik olmayan riski

Sistematik Risk: Ülkenin ekonomik koşullarından kaynaklanan ve piyasa da oluşan olumlu veya olumsuz yöndeki değişimlerin tüm menkul kıymetler üzerinde etkisine sistematik risk denilmektedir. Sistematik risk, tüm varlıkla üzerinde aynı etkiyi gösterdiği için portföy üzerinde bir çeşitlendirme yapılsa bile ortadan kaldırılamamaktadır (Sevinç, 2007).

Sistematik riskin kaynakları şunlar:

Satın Alma Gücü Riski: Enflasyon riski de olarak da bilinmektedir. Fiyat seviyesindeki dalgalanmalardan dolayı satın alma gücünde meydana gelen kayıpları ifade eder (Kaya,2012).

Faiz Oranı Riski: Piyasa faiz oranındaki değişimler sonucunda menkul kıymetlerin getirilerinde meydana gelen değişikliği ifade etmektedir.

Menkul kıymetler ile faiz oranları arasında ters yönlü bir ilişki görülmektedir. Yani birinin oranındaki yükselme diğerinin düşüşüne sebep olmaktadır (Kaya, 2012).

Piyasa Riski: Menkul kıymetlerin getirilerindeki deęişikliklerin siyasi kararlar, seçimler, savaşlar gibi daha çok psikolojik etkenlerin ortaya çıkardığı risktir. Düşük kaliteli hisse senetleri yüksek kaliteli hisse senetlerine göre piyasa riskinden daha çok etkilenirler (Ceylan ve Korkmaz, 2000).

Politik Risk: Dünya genelinde yaşanan siyasi ve ekonomik krizler sonucunda karşılaşılan risktir. Döviz kurlarında yaşanan deęişimler ve yabancı sermaye yatırımları bu riskin kaynaklarını oluşturmaktadır (Kaya, 2012).

Kur Riski: Yatırımların yabancı para ile yapılması durumunda paranın deęeri düşmesi kur riski olarak adlandırılmaktadır (Kaya, 2012).

Sistemik Olmayan Risk: Belli bir sektöre ait olan ve çeşitlendirme ile azaltılabilen risk türüdür. İlgilenilen sektöre ait olayların gerçekleşme sıklığına göre sistemik olmayan riskin derecesi belirlenmektedir. Genel olarak yeni buluşlar, grevler, yatırım kararlarının başarısız olması, reklam kampanyaları, yönetimde meydana gelen başarısızlıklar vb. gibi konular sistemik olmayan riskin unsurlarını oluşturmaktadır. Sistemik olan riskin aksine portföyde yapmış olduğumuz çeşitlendirme ile bu risk türünü minimuma indirebiliriz.

Sistemik olmayan riskin kaynakları şunlar:

Finansal Risk: Firma borçlarının artış göstermesi, grevler, teknolojiye uyum sağlayamamak, rekabetin artması vb. nedenlerle firmanın finansal açıdan borç ödeyebilme gücünün azalmasıdır (Kaya, 2012).

İş ve Endüstri Riski: Firma üzerinde meydana gelen olumsuz gelişmelerin tamamını ifade eder (Kaya, 2012).

Yönetim Riski: Yönetimin almış olduğu yanlış kararlardan meydana gelen risktir (Kaya, 2012).

Risk Ölçüleri: Ortalama sapma, varyans ve standart sapma riskin hesaplanmasında temel unsurları oluşturmaktadır.

Ortalama sapma; beklenen değerden sapmaların mutlak değerlerinin toplamından elde edilir.

$$OS = \sum_{i=1}^n |R_i - E(R_i)| x_i \quad (5.3)$$

Varyans; beklenen getiriden sapmaların karelerinin ortalamasıdır.

$$\sigma^2 = \frac{\sum_{i=1}^n (R_i - E(R_i))^2}{n} \quad (5.4)$$

Standart sapma; varyansın kareköküdür. Standart sapma, finansal varlığın beklenen getirisinden farklı bir getiri ile karşılaşma olasılığını gösterir. Standart sapmanın riskle doğru orantılı olarak ilerlemektedir.

$$\sigma = \frac{(\sum_{i=1}^n (R_i - E(R_i))^2)^{1/2}}{n^{1/2}} \quad (5.5)$$

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

Matematiksel olarak kovaryans aşağıdaki formülle hesaplanmaktadır:

$$Cov(R_x, R_y) = \frac{\sum_{i=1}^N (x_i - \bar{x})(y_i - \bar{y})}{n-1} \quad (5.6)$$

x_i : x değişkeni

y_i : y değişkeni

\bar{x} : x değişkenlerinin ortalaması

\bar{y} : y değişkenlerinin ortalaması

N: toplam veri sayısı

Bu formülle bulduğumuz değer şu şekilde yorumlanabilir:

- Bulunan değer pozitif ise rasgele değişkenler arasında aynı yönlü hareket etmektedir.
- Bulunan değer negatif ise rasgele değişkenler farklı yönlü hareket etmektedir.
- Bulunan değer sıfır ise rasgele değişkenler arasında ilişki yoktur ve birbirlerinden bağımsızdırlar.

Korelasyon Katsayısı: Bağımsız iki değişken arasındaki kovaryansın standart sapmalarının çarpımına bölünmesiyle hesaplanmaktadır. Bu değer değişkenler arasındaki ilişkinin gücünü belirlemektedir.

Matematiksel olarak korelasyon katsayı aşağıdaki formülle hesaplanmaktadır:

$$\rho_{A,B} = \frac{\text{Cov}(R_A, R_B)}{\sigma_A \sigma_B} \quad (5.7)$$

Burada;

σ_A :A değişkeninin riski

σ_B :B değişkeninin riski

$\rho_{A, B}$: A ve B değişkenleri arasındaki korelasyon katsayısı

$\text{Cov}(R_A, R_B)$: A menkul değeri ile B menkul değerinin getirileri arasındaki kovaryans değeri.

Korelasyon bulduğumuz değerlere göre değişkenlerin gücüne ilave olarak ilişkinin yönünü de belirlemektedir. Bu katsayı -1 ile 1 arasında değer almaktadır.

- İki rasgele değişken arasındaki korelasyon katsayısı sıfırdan büyük ve +1 yakın ise değişkenler arasında aynı yönlü (pozitif) güçlü bir ilişki bulunmaktadır.
- İki rasgele değişken arasındaki korelasyon katsayısı sıfırdan küçük ve -1 yakın ise değişkenler arasında ters yönlü (negatif) güçlü bir ilişki bulunmaktadır.
- Korelasyon katsayısının sıfır ya da sıfıra yakın olması durumunda ise değişkenler arasında ilişki bulunmadığı söylenir.

Hisse senetlerinin korelasyon katsayısının -1'e yakın olması değişkenler arasında ters yönlü ilişki olduğu anlamına gelir ve bu da portföyün riskini azaltan bir durumdur.

Beta Katsayısı: Beta katsayısı, optimal bir portföyün risk seviyesini belirleyen ölçütlerden biridir. Menkul kıymetlerin piyasa karşı olan duyarlılığı ve oluşturulan portföyün risk ile getiriye olan katkısı beta katsayısıyla ölçülmektedir. Beta katsayısının model gösterimi aşağıdaki gibidir:

$$r_{i,t} = \alpha_i + \beta_i r_{m,t} + \varepsilon_{i,t} \quad (5.8)$$

$r_{i,t}$: i hisse senedinin t zamandaki getirisi

α_i : kesişim / sabit terim

β_i : beta/ risk/ eğim katsayısı

$r_{m,t}$: piyasa endeksinin t periyodundaki değişim oranı

ε_{it} : hata katsayısı

t: zaman indisi

Beta katsayısı yatırım yapılacak olan hisse senetlerinin piyasadaki dalgalanmalarını göstermektedir. Başka bir ifadeyle hisse senedinde meydana gelen bir birim değişim aynı zamanda portföyün varyansında da meydana gelen değişimi göstermektedir. Yatırımcı yatırımını yaparken hisse senedinin bu zamana kadar piyasa da olan değişimini inceleyecektir. Bu açıdan beta katsayısı oldukça büyük bir önem taşımaktadır. Beta katsayısı aşağıdaki formülle hesaplanmaktadır:

$$\beta_i = \frac{\text{cov}(r_i, r_m)}{\text{var}(r_m)} \quad (5.9)$$

- $\beta > 1$ ise, hisse senedinin, piyasa getirisi ile aynı yönde, hatta daha büyük bir değişim gösterecek demektir (Karaşin,1986). Bu şekilde değerlendirilen hisse senetlerine atak hisse senetleri adı verilmektedir.
- $+1 > \beta > -1$ durumunda hisse senedinin getirisi, piyasa getirisinden daha küçük bir değişim gösterecek demektir.
- $\beta < -1$ ise, hisse senedinin, piyasa getirisi ile ters yönde hatta daha küçük bir değişim gösterecek demektir. Bu şekilde değerlendirilen hisse senetlerinin piyasa duyarlılıkları zayıftır. Bu tür senetlerine tutucu hisse senedi adı verilmektedir.

Piyasanın beta katsayısı her daim 1 olarak alınır. Bir hisse senedinin beta katsayısının 1 olması piyasa ile aynı riske sahip olduğunu göstermektedir.

5.4.1. Portföy Çeşitleri

Yatırımcıların riski göze alması veya kaçması tercihlerine göre ideal bir portföy oluşturmaları gerekmektedir. Bu durum göz önünde bulundurulduğunda portföylerin çoğunlukla hisse senedi ve tahvillerden oluştuğu söylenebilir. Portföy çeşitleri 4 grup altında incelenmektedir bunlar;

5.4.1.1.Tamamı Tahvillerden Oluşturulan Portföyler

Tahvil; bir yatırımcının devlet veya kurumsal işletmelerin finansman ihtiyacını karşılamak amacıyla onlara belirli bir süre değişken ya da sabit bir faiz oranı ile borç verdiği ve vade sonunda faiz getirisi elde ettiği bir yatırım biçimidir. Vadesi 1 yıldan fazla olan tahvil, yazılı bir senettir. Tahvil sahibi olan yatırımcı, tahvil ihraççısının alacaklısı konumundadır.

Risk almayı sevmeyen yatırımcının ve piyasayı izlemekte güçlük çeken tasarruf sahiplerinin tercih ettikleri portföy çeşididir. Sağlam bir yatırım türü olabileceği için bu tür portföylerin ekonominin resesyon dönemlerinde oluşturulmasında yarar vardır (Usta,2008). Bu portföy çeşidi devlet tahvilleri, hazine bonoları ve işletimlerin çıkardığı tahvillerden meydana gelmektedir.

5.4.1.2.Tamamı Hisse Senetlerinden Oluşturulan Portföyler

Bu tür portföylere yatırım yapılırken daha önceden piyasanın detaylı bir şekilde gözden geçirilmesi gerekmektedir. Oluşturulan portföyde bulunan hisse senetlerinin istenildiği zaman alım-satım yapılabilmesi özelliğine sahip olması gerekmektedir. Başarıya ulaşabilmek için ekonominin istikrarlı olduğu dönemler seçilmelidir.

5.4.1.3.Hisse Senetleri ve Tahvillerden Oluşturulan Portföyler

Portföy çeşitleri arasında en çok tercih edilen türdür. Yatırımcı, oluşturacağı portföyünü bulunduğu mevcut ekonomik koşulları da dikkate alarak hisse senedi, tahvil vb. menkul kıymetler arasında belli oranlarda bölüştürmektedir (İnam, 1987).

Ekonomide oluşan dalgalanmalara göre yatırımcının tercihleri de farklılık gösterebilmektedir. Yatırımcı, ekonominin durgun olduğu dönemlerde daha az risk almayı tercih ettiği için tahvile yatırım yaparken, ekonominin canlandığı dönemlerde risk alarak tercihlerini hisse senetlerinden yana kullanmaktadır.

5.4.1.4. Diğer Yatırım Araçlarından Oluşturulan Portföyler

Hazine bonoları, repo, vadeli sözleşmeler, döviz, varlığa dayalı menkul kıymetler, finansman bonoları gibi yatırım araçlarından oluşmaktadır.

5.5. Optimum Portföy

Son yıllarda gelişen teknoloji ile birlikte optimizasyon modellerinin kullanımı artmaktadır. Risk yönetimi ve portföy yönetimi gibi birçok finansal problemin çözümünde optimizasyon yöntemleri ile başarılı sonuçlar elde edilmektedir.

Optimum portföyü oluştururken yatırımcılar tercihlerini beklenen getiriye maksimum riski minimum yapmaktan yana kullanırlar. Uygulamada karşımıza çıkan neredeyse tüm problemlerde bu iki durum birbiri ile çelişir.

5.6. Menkul Kıymet Seçimi

Menkul kıymetlerin seçiminde hangisinin seçileceği temel ve teknik analiz olmak üzere iki yöntemle belirlenir.

5.6.1. Temel Analiz

Finansal varlığı ihraç edilmiş olan firmanın performansını etkileyen ekonomik, sektörel ve ortaklıkla ilgili unsurları dikkate alan, finansal varlığın gerçek değerini bulmaya ve bulunan gerçek değeri piyasa fiyatı ile karşılaştırarak alım-satım kararını vermeye yarayan analiz yöntemi "temel analiz" olarak adlandırılır (Bekçi, 2001).

Temel analiz şirketlerin finansal durumlarının incelenmesine dayalı bir yöntemdir. Bu analiz yöntemini uygulayanlar yatırım yapmak istedikleri hisse senedinin değer gördüğü fiyatı ile cari fiyatını karşılaştırarak yatırım kararını veririler. Hisse senedinin gerçek değerinin belirlemek için şirketin bulunduğu sektörün durumu, ülke ekonomisi, pazar

payı ve bilançoların detaylı bir şekilde incelenmesi gerekmektedir (Bolak, 1994; Özçam, 1996).

Portföye seçilecek hisse senetleri nitelikleri göz önünde bulundurularak seçilir. Hisse senetlerinin performansları sayısal verileri incelenerek tahmin edilmeye çalışılır. Portföy oluşturulurken sadece firma bilgileri değil aynı zamanda ülke ekonomisi, uluslararası ve ulusal olaylar da incelenmelidir. Temel analiz üç başlığa ayrılmaktadır. Bunlar;

1. Ekonomik Analiz
2. Sektör Analizi
3. Firma Analizi

Temel analizde ilk olarak ülke ekonomisi göz önünde bulundurulur. Bu inceleme sırasında dikkat edilen hususlar aşağıda belirtilmiştir.

- Faiz oranları,
- Para arzı ve talebin dengesi,
- Enflasyon oranları,
- Dış ticaret açıkları,
- Ödemeler dengesi açıkları,
- Banka faiz oranları,
- Döviz fiyat hareketleri,
- Kamu kesimi harcamaları,
- Merkez bankası para politikaları.

Bu analizin en önemli aşaması firma analizi kısmıdır. Yatırımcı firmanın geçmiş dönem performanslarını inceleyerek bulunulan dönem için yatırım kararı verilip verilmemesi konusunda tahminlerde bulunabilir. Bu şekilde daha sağlıklı bir yatırım kararı verilecektir. Firmalar için incelenmesi gereken birçok rapor, tablo ve bilgi bulunmaktadır. Uzmanlarda bu veriler ışığında yorum yapmak ve firma analizlerine ayrıca bir önem vermek durumundalardır (Karan, 2001).

5.6.2. Teknik Analiz

Teknik analiz, geçmişte gerçekleşen fiyat ve işlem değerlerini dikkate alarak geleceği tahmin etmeye çalışan bir analiz yöntemi olarak ortaya çıkmıştır ve yaygın olarak kullanılmıştır.

Temel olarak teknik analiz geçmişteki fiyat hareketleri göz önünde bulundurularak hisse senedinin fiyatını tahmin etmeye çalışmaktır. Teknik analiz içerisinde birçok gösterge bulunmaktadır. Bunların birçoğu istatistiksel hesaplamalar ile ortaya çıkmıştır. Medyan, korelasyon katsayısı, standart sapma ve hareketli ortalamalar buna örnek verilebilir.

Teknik analizde verileri yorumlayabilmenin en kolay ve yaygın yolu grafiklerdir. Yatırım uzmanları matematiksel yöntemler ve grafikler aracılığıyla yatırım yapacakları hisse senedi fiyatının trendine ve bu trendlere ilişkin geleceğe yönelik tahminlerde bulunabilir.

18.yy. başlarında Londra Borsası'nda sıkça bahsi geçen boğa ve ayı piyasası terimleri kullanılmaktaydı. Bu terimler piyasada bulunan bazı kesimlerin gelecek hakkındaki tahminlerinin yönünü belirlemekteydi. Teknik analizde de belli kesimlerin piyasa fiyatlarını belirlemesi nedeniyle boğa ve ayı terimlerine sıkça yer verilmektedir.

Teknik Analiz Araçları

1. Destek ve Direnç Kavramları

“Destek seviyesi, fiyatların düşerken durduğu veya sıkıştığı gelen taleplerle birlikte yükselişin başladığı seviyeyi göstermektedir. Direnç seviyesi ise fiyat artışlarının önünü kesen önemli derecede bir arzın oluştuğu, yükselişin durduğu veya yavaşladığı seviyeyi ifade etmektedir” (Kardiyen, 2007).

2. Trend

Teknik analizde fiyatlar bir trend çerçevesinde belirlenmektedir. Arz ve talep bu trende yön vermektedir. Trendler yukarı, aşağı veya yatay olabilmektedirler. Bu durumda yükselen trend (boğa piyasası), alçalan trend (ayı piyasası), veya yatay trend söz konusudur. Bunlara ek olarak trendler zaman süreci bakımından da 3 ayrılmaktadır. Bunlar;

- Uzun vadeli trend (major primary trend)
- Orta vadeli trend (intermediate trend)
- Kısa vadeli trend (minor trend)

3. Trend Çizgileri

Trendin hangi yönde ilerleyeceğini gösteren çizgilerdir. Bu çizgiler tepe veya dip noktalardan geçen düz bir çizgiye dizilir. Piyasalardaki fiyatların artış ve azalışına göre bu çizgilerde yön değiştirmektedir

4. Trend Kanalları

Fiyatların, trend çizgisine karşı olan hareketlerini göstermektedir.

5.7.Portföy Yönetimi Yaklaşımları

Portföy yönetimi geleneksel portföy teorisi ve modern portföy teorisi olmak üzere ikiye ayrılmaktadır. Bu iki yaklaşımın temelinde de çeşitlendirme ilkesi ile riskleri minimum getiriyi maksimum yapmak yatmaktadır.

5.7.1. Geleneksel Portföy Teorisi

Bu teori, 1950’li yıllara kadar bilimsel bir temele dayanmamasına rağmen uygulama kolaylığı nedeniyle kendine çok fazla kullanım alanı bulmuştur. Günümüzde hala birçok yatırımcı tarafından kullanılmaya devam etmektedir. Bu yaklaşımın amacı yatırımcıların öngörülen risk seviyesindeki getirilerini maksimum yapmayı hedeflemesidir (Bekçioğlu, 1984).

1968 yılında Evans ve Archer tarafından “Birden fazla varlığa yatırım yapılması görüşüne dayandığı için bütün yumurtaların aynı sepete konulmaması” olarak da tanımlanabilir.

Yatırımcılar genelde *yalın çeşitlendirme* ilkesi doğrultusunda hareket etmektedirler. Bu ilkenin temelinde portföy performansı ile menkul kıymet arasında bir ilişki olduğunu savunulmaktadır. Yatırımcı birçok farklı sektörden menkul kıymet seçerek çeşitliliği artırmaktadır ve böylelikle portföyde oluşabilecek risk seviyesinin minimum olacağı tahmin edilmektedir (Francis ve Archer,1971).

Geleneksel Portföy Teorisi'nde;

- Yatırımcıya ait bilgilerin toplanması
- Portföy amacının saptanması
- Yatırım politikaları
- Portföye dahil edilebilecek menkul kıymetlerin seçilmesi aşamaları izlenmektedir (Yalçın,2006).

Bu yaklaşımda portföydeki aşırı çeşitlendirme karşımıza çıkabilecek en büyük sorundur.

Bu sorunun ortaya çıkardığı bazı sakıncalar aşağıdaki gibidir:

- Portföyde çok sayıda menkul kıymetin bulunması nedeniyle portföy maliyetinin artması,
- Portföy oluşturulurken menkul kıymetin taşıdığı riske dayanarak beklenen getiriyi sağlamayan varlıkların satın alınması,
- Menkul kıymet sayısının artmasıyla komisyon masraflarının artması,
- Bu yaklaşımda çeşitlendirme yapılarak riskten koruma sağlanmaya çalışılsa da yatırımları piyasada yaşanana ani düşüşlerden korumak mümkün değildir.

Bu olumsuzluklar doğrultusunda 1950 yıllarının başında geleneksel portföy analizinin yerini varlıklar arasındaki getirilerin ilişkilerini inceleyen modern portföy teorisi almıştır.

5.7.2. Modern (Markowitz) Portföy Teorisi

1950'li yıllardan öncesinde yatırımcıların portföy oluşturabilmesi için geleneksel portföy yönetimi fazlasıyla yeterli olmuştur. Bu yaklaşımda yatırımcılar menkul kıymet ve getiri arasındaki ilişkiyi göz ardı ederek, portföydeki çeşitliliği artırıp riski azaltabileceklerini savunmuşlardır. Fakat modern portföy teorisinde aynı yöntemi uygulamak istediklerinde portföy çeşitlendirmeyeyle riskin azaltılamayacağı görülmüştür. Bunun nedenin portföyde bulunan finansal varlıkların aynı ya da zıt yönlü hareket etmeleri olduğu söylenmektedir (Ertuna, 1983).

Modern portföy yaklaşımı, bazı araştırmacılar tarafından 1950'li yıllarda optimum portföylerin matematiksel formülasyonunu bulabilmek için ortaya atılmıştır. İleri sürülen çalışmalarda belirlenen risk düzeylerinde tahmin edilen en yüksek getiri için menkul

kıymet kombinasyonları oluşturulması hedeflenmiştir. Bu hedeflere ulaşabilmek için bilgisayar kullanımına ihtiyaç duyulmuştur. Bilgisayar kullanımı ile birlikte maliyet düşürülmüş ve gelir arttırılmıştır. Bu durum sonucunda özellikle akademisyenler tarafından daha sık kullanılmaya başlanmış ve modern portföy yaklaşımının gelişimi hızlanmıştır.

1952 yılından Haryy Markowitz tarafından hazırlanan “Portföy Seçimi” adlı çalışmada modern portföy teorisi yaklaşımı çıkmıştır. Bu çalışmada portföy oluşturulurken en yüksek getirili menkul kıymete değil birçok menkul kıymete yatırım yapılmasının önemine dikkat çekilmiştir. Markowitz çalışmalarında portföydeki menkul kıymetlerin getiri ve riskinin ağırlıklarının yatırımlara nasıl dağılacağını ve performanslarına göre optimal varlık paylaşımını göstermiştir (Oberuc, 2003).

Modern portföy teorisi yatırımcıların getirilerini maksimum yapabilmesi için 4 ayrı model içermektedir. Bunlar;

1. Markowitz ortalama-varyans modeli
2. İndeks modeller
3. Sermaye varlıklarını fiyatlama modeli
4. Arbitraj fiyatlama modeli

5.7.2.1. Markowitz Ortalama- Varyans Modeli:

Bu model yatırımcı tarafından hedeflenen getiri düzeyi için portföyün riskini minimum yapacak ağırlıkların belirlenmesi esasına dayanmaktadır. Ortalama-varyans modeli, maksimum getiri için yüksek risk ya da minimum risk için düşük getiriye sahip portföylerden oluşmaktadır.

Markowitz tarafından öne sürülen bu yaklaşım yatırımcı davranışları ile oluşturulan portföy arasında bir ilişki olduğunu savunmaktadır. Böylelikle yatırımcı davranışları ve portföydeki çeşitlendirme ilkesinin birbirini tamamlaması ile optimum portföyü elde etmemiz çok daha kolay olacaktır. Markowitz, optimum portföy için beklenen getiri ve beklenen getirinin varyansı kullanılarak oluşturulması gerektiğini savunmaktadır. Ortalama-varyans modelini kullanarak portföydeki çeşitlendirme ile aynı getiri-risk kombinasyonu oluşturulabilir.

Markowitz Ortalama- Varyans Modeli iki varsayıma dayanmaktadır. Bunlar:

1. Yatırımcılar riskten kaçan bireylerdir.
2. Yatırımların olasılık dağılımı yaklaşık olarak normal dağılımdır.

Bu varsayımlar doğrultusunda yatırımcı aynı seviyede getiriye sahip seçeneklerden standart sapması düşük ya da standart sapması aynı ama getirisi fazla olan seçeneği seçecektir (Ceylan ve Korkmaz, 1995).

Markowitz 'in öne sürmüş olduğu çeşitlendirme ilkesi, yalın çeşitlendirmenin aksine çok daha analitiktir ve varlıkları korelasyon katsayılarını dikkate alarak değerlendirme yapar. Markowitz 'in çeşitlendirmesi portföyün riskini düşürmek için varlıklar arasında negatif ilişki bulunanları bir araya getirmektedir. Korelasyon ile risk doğru orantılı olarak hareket etmektedir. Varlıklar arasındaki korelasyon katsayısının azalması riskin de azalmasını sağlar (Fisher, 1979).

Portföyün Getirisi ve Riski

Bir portföyün getirisi en basit şekilde portföydeki varlıkların getirilerinin ağırlıklı ortalamasıdır.

$$r_p = \sum_{i=1}^n w_i r_i \quad (5.10)$$

r_p : portföy getirisi

r_i : her bir menkul kıymetin getirisi

w_i : her bir menkul kıymetin portföydeki ağırlığı

Bir portföyün beklenen getirisi varlıkların beklenen getirilerinin ağırlıklı ortalamasıdır.

$$\bar{r}_p = \sum_{i=1}^n w_i \bar{r}_i \quad (5.11)$$

\bar{r}_p : portföyün beklenen ağırlıklı getirisi

\bar{r}_i : i. menkul kıymetin beklenen ağırlıklı getirisi

w_i : i. menkul kıymetinin portföydeki ağırlığı

Markowitz'e göre portföyün riski aşağıdaki gibi hesaplanmaktadır.

$$\sigma(r_p) = \sqrt{\sum_{i=1}^n \sum_{j=1}^n w_i w_j \text{Cov}(r_i r_j)} \quad (5.12)$$

$\sigma(r_p)$: portföy riski

$\text{Cov}(r_i r_j)$: menkul kıymetler arasındaki kovaryans

$$\sigma(r_p) = \sqrt{\sum_{i=1}^n \sum_{j=1}^n w_i w_j \sigma(r_i) \sigma(r_j) \rho_{r_i, r_j}} \quad (5.13)$$

$$\text{Cov}(r_i r_j) = \sigma(r_i) \sigma(r_j) \rho_{r_i, r_j} \quad (5.14)$$

σ : menkul kıymetlerin riski

ρ_{r_i, r_j} : menkul kıymetlerin arasındaki korelasyon katsayısı

olmak üzere iki farklı formülle ifade edilir.

İki menkul kıymetten oluşan portföylerde standart sapma aşağıdaki formülle ifade edilir.

$$\sigma(r_p) = [w_1 \sigma^2(r_1) + w_2 \sigma^2(r_2) + 2w_1 w_2 \text{Cov}(r_1, r_2)]^{1/2} \quad (5.15)$$

$$\text{Cov}(r_1 r_2) = \sigma(r_1) \sigma(r_2) \rho_{r_1, r_2} \quad (5.16)$$

$\rho_{r_1, r_2} = -1$ olduğu durumda iki menkul kıymetten birinin getirisinin artması diğerinin getirisinin düşmesi durumunda portföyün riski ortadan kalmış olur.


$\rho_{r_1, r_2} = 1$ olduğu durumda ise çeşitlendirme ilkesi ile riskin azaltılması mümkün olmamaktadır.

Etkin Portföy

Etkin portföy, bir düzeydeki tahmin edilen getiri için portföyün minimum seviyedeki riske sahip olmasıdır. Daha açık ifadeyle belirli bir risk seviyesinde portföyün maksimum getiriyi sağlamasıdır.

Etkin Sınır (Efficient Frontier)

Çok sayıda finansal varlığa sahip bir piyasada, varlıklara verilen ağırlıklar ile birçok farklı portföy oluşturulabilir. Risk ve beklenen getiriler için oluşturulan etkin portföylerin birleşmesiyle oluşan eğriye *etkin sınır* adı verilmektedir. Etkin sınır üzerindeki noktalar optimal portföyleri oluşturmaktadır. Bu eğri üzerinde uç noktalarda bulunabilmektedir. Piyasada bulunan minimum risk ve maksimum getirili finansal varlıklar bu eğri üzerindeki uç noktaları temsil etmektedir.



Şekil 5.2. Etkin Sınır ve Erişilebilen Portföyler (Dağlı, 2004).

Şekil 5.2.'de görüldüğü gibi erişilebilen portföyler kümesi etkin sınırın üzerinde yer almaktadır ve bu portföyler risk-getiri oranı en yüksek olan gruptur. Etkin sınırın alt bölümünde erişilebilen fakat etkin olmayan portföyler kümesi yer alırken, etkin sınırı üstünde erişilmesi mümkün olmayan portföy kümesi bulunmaktadır.

5.7.2.2.İndeks Modeller

Optimum portföyü bulabilmek için;

- Her menkul kıymetin beklenen getirisinin,
- Her bir finansal varlığın standart sapma ve varyansının,
- Menkul kıymetler ikiyeşerli kombinasyonlar halinde alınması durumunda da kovaryanslarına hesaplanması gerekmektedir.

Finansal varlıkların çok sayıda olması durumunda bu bilgilerin bulunması çok fazla hesaplama gerektirecektir. Markowitz çeşitlendirmesinin bu kadar çok işlem yüküne

sebebi olması ve zaman kaybı yaratması nedeni ile William Sharpe tarafından basit indeks modeli öne sürülmüştür. Bu modelde tek bir finansal varlığın beklenen getirisi ile tek bir indeks arasındaki ilişkinin doğrusal olduğu düşünülmektedir (Horne, 1978). İndeks modelleri tekli ve çoklu indeks model olarak ikiye ayrılmaktadır. Tekli ve çoklu indeks modelleri işlem yükünün azalması nedeniyle portföyün beklenen getiri ve riskinin bulunabilmesi için veri sayısını oldukça azaltmıştır.

Tek İndeks Modeli

Tek indeks model finansal varlığın beklenen getirisi ile indeks arasında doğrusal bir ilişki olduğu savunmaktadır. William Sharpe optimal portföyün her bir menkul kıymet için varyans, standart sapma ve kovaryans bilgilerine ihtiyaç duyması nedeniyle modeli daha basit bir hale getirmiştir. Böylelikle optimal portföyü oluşturmak için gerekli veri sayısını azaltmayı hedeflemiştir (Haugen, 2001).

Tek endeks modelinde her bir menkul kıymetin getirisi aşağıdaki denklem ile ifade edilebilir:

$$r_i = \alpha_{0i} + \beta_i r_m + \varepsilon_i \quad (5.17)$$

r_i : i. menkul kıymet getirisi

α_{0i} : regresyon sabiti

β_i : menkul kıymet getirisinin piyasa getirisine olan hassasiyeti

r_m : piyasa getirisi

ε_i : hata katsayısı

(Elton ve Gruber, 1973).

Bu modelin temel dayanağı menkul kıymetlerin birbiriyle olan ilişkileridir. Buna göre diğer varsayımlar:

$$E(\varepsilon_i(r_m - \bar{r}_m)) = 0, i=1,2,\dots,N \quad (5.18)$$

$$E(\varepsilon_i \varepsilon_j) = 0, i=1,2,\dots,N, j=1,2,\dots,N, i \neq j \quad (5.19)$$

$$\text{Beklenen getiri: } \bar{r}_i = \alpha_{0i} + \alpha_i \bar{r}_m \quad (5.20)$$

$$\text{Bir menkul kıymetin getirisinin varyansı: } \sigma_i^2 = \alpha_i^2 \sigma_m^2 + \sigma_{\epsilon_i}^2 \quad (5.21)$$

$$\text{i ve j menkul kıymetlerinin getirileri arasındaki kovaryans: } \sigma_{ij} = \alpha_{0i} \alpha_j \sigma_m^2 \quad (5.22)$$

Çoklu İndeks Modeli

Çoklu indeks modeli finansal varlıkların getirilerinin sadece piyasa indeksine değil birçok farklı değişkene bağlı olarak değişkenlik gösterdiği varsayılmaktadır. Piyasa dışında kalan indekslere örnek olarak; faizler ve enflasyon verilebilir. Bu model piyasa dışında kalanların getirileri bağımsız değişken, finansal varlıkların getirileri ise bağımlı değişken olarak kabul edilen bir regresyon modelidir.

Çoklu indeks modelin denklemini aşağıdaki gibidir:

$$r_i = \beta_0 + \beta_{i1} I_1 + \beta_{i2} I_2 + \dots + \beta_{iL} I_L + \epsilon_i \quad (5.23)$$

r_i : i. menkul kıymet getirisi

I_L : menkul kıymet getirisini etkileyebilecek endeks düzeyleri

β_{iL} : i menkul kıymetinin L endeksindeki değişikliklere duyarlılığı

β_0 : regresyon sabiti

ϵ_i : hata katsayısı

L: endeks sayısı

(Elton ve Gruber, 1973).

5.7.2.3.Sermaye Varlıklarını Fiyatlama Modeli (SVFM)


Piyasada yatırımcıların tercih edebileceği birçok seçenek bulunmaktadır. Her bir yatırımcı farklı düzeyde riski tercih etmektedir ve farklı düzeyde sermaye ile yatırımda bulunmaktadır. Bu nedenle piyasada bulunan yatırımcıların davranışlarının ne olacağını belirlemek çok zordur. Yatırımcıların bu davranışlarına ilişkin riski kontrol edebilmek ve risk-getiri arasındaki dengeyi sağlayabilmek için bazı modellere ihtiyaç duyulmaktadır. Bu modellere “Genel Denge Modelleri” adı verilmektedir. Bu modellerin en temel örneklerinden birisi “Sermaye Varlıklarının Fiyatlama Modelidir (SVFM)”.

SVFM Markowitz 'in modern portföy kuramı üzerine kurulmuş bir teoridir. Bu teorinin temeli oluşturduğumuz portföye risksiz menkul kıymetleri dahil ederek yeni bir kombinasyon oluşturmaya dayanmaktadır. Oluşturulan kombinasyonda menkul kıymetin beklenen getirisi ve riski arasında doğrusal bir ilişki kurulur. Kurulan bu ilişki SVFM ile ifade edilebilir (Köse, 2001).

Bu modelde risksiz menkul kıymetlerin de dahil edilmesi yatırımcıların davranış ve tutumlarında oldukça fazla bir esneme sağlamaktadır. Bu durumla ortaya yatırımcının bireysel oluşturduğu portföy ile risksiz yatırımın birleşmesinden oluşan bir karma portföy ortaya çıkmaktadır. Yatırımcının elindeki sermayenin bir kısmının risksiz yatırımlara kalan kısmının ise hisse senetlerine yatırılması sonucunda bütün odak noktalar sermaye pazarı doğrusu üzerine toplanacaktır. SVFM ile bir finansal varlık arasındaki beklenen getiri aşağıdaki eşitlik ile hesaplanmaktadır.

$$\bar{r}_i = r_F + \beta_i(\bar{r}_M - r_F) \quad (5.24)$$

Tüm finansal varlıkların ve portföylerinin beklenen getirisi bu eşitlik ile ifade edilmektedir. Eşitlik 5.24' de \bar{r}_M piyasanın portföyünün getirisini r_F ise risksiz varlığın getirisini göstermektedir. İki finansal varlığın betaları arasındaki fark aynı zamanda finansal varlıkların beklenen getirileri arasındaki ilişkiyi de ortaya koymaktadır. Getiri beta katsayısıyla doğru orantılı olarak ilerlemektedir. Bir varlığın betası ne kadar büyük ise getirisi de o kadar fazladır.



Şekil 5.3. Sermaye Piyasası Doğrusu

Şekil 5.3.'de görülen doğru hem menkul kıymetler için hem de portföyler için denge getiriyi ifade etmektedir.

SVFM varsayımları;

- Yatırım kararlarının tamamı getirilerin olasılık dağılımına göre verilir. Bu olasılık dağılımının normal dağılıma yaklaştığı varsayılır.
- Piyasada yapılan işlemlerin maliyeti sıfırdır.
- Gelir vergisi bulunmamaktadır.
- Fiyat düşme beklentisi içinde olan yatırımcı elinde olmayan menkul kıymetleri satabilir.
- Yatırımcılar kararlarını beklenen getirilere ve bu getirilerin standart sapmalarına göre vermektedir.
- Yatırımcılar risksiz bir şekilde borç alıp verebilir.
- Bütün yatırımcılar için tam rekabet şartları geçerlidir.
- Bütün sermaye varlıkları pazarlanabilirler (Özçam, 1997; Üstünel, 2000).

5.7.2.4.Arbitraj Fiyatlama Teorisi (AFT)

AFT, 1970'li yılların başlarında Ross tarafından geliştirilmiştir. SVFM beta katsayısı ile getiri arasındaki ilişkiyi göstermektedir. Fakat varsayımlarını nedeniyle beklenen getirileri net bir şekilde açıklayamamaktadır. Bu nedenle ek bir seçenek olarak AFT geliştirilmiştir. AFT, varlık fiyatlarını açıklama ve finansal varlıkların iki farklı fiyattan satışa sulanamayacağı üzerine kurulmuş bir modeldir (Üstünel, 2000).

SVFM ve AFT birbirlerine benzer modellerdir. Fakat AFM çok faktörlü bir model iken SVFM ise tek faktörlü bir model olma özelliğine sahiptir. SVFM'ye göre daha az varsayıma sahiptir.

AFT 3 adet varsayıma dayanmaktadır. Bunlar:

- Sermaye piyasalarında tam rekabet koşulları söz konusudur.
- Yatırımcılar her zaman risk seviyesi aynı olsa bile yüksek getiriye tercih ederler.
- Sistemik risk SVFM' de olduğu gibi tek bir faktör tarafından temsil edilmek zorunda değildir (Altınırmak, 2003).

AFT modelinin denklemi aşağıdaki gibi görülmektedir;

$$r_{it}=E(r_i)+b_{i1}\delta_{1t}+b_{i2}\delta_{2t}+\dots+b_{ik}\delta_{kt}+e_{it} \quad (5.25)$$

r_{it} : i. varlığının getirisi, $i=1, 2, \dots, n$

$E(r_i)$: i. menkul kıymetin beklenen getirisi

δ_j : tüm menkul kıymetlerde getiriye etkileyen faktörler, $j=1, 2, \dots, k$

b_{ij} : i. menkul kıymetin j. ortak faktörüne duyarlılığı

e_{it} : i. menkul kıymetin sistematik olmayan riski

n : menkul kıymet sayısı

Ek olarak,

$$E(\delta_j)=0, J=1,2,\dots,k \quad (5.26)$$

$$E(e_i)=0, i=1,2,\dots,n \quad (5.27)$$

$$E(e_i e_h)=0, i \neq h \quad (5.28)$$

$$E(e_i^2)=\sigma_i^2 < \infty \quad (5.29)$$

varsayılmaktadır.

5.7.3. Modern Portföy Modelinin Çeşitlendirilmesi

Literatürde portföy çeşitlendirmesi ilk kez Markowitz tarafından ileri sürülmüştür. Korelasyon katsayısı ile portföyün riski arasında oluşan doğrusal ilişki nedeniyle çeşitlendirme yapılırken korelasyon katsayısına dikkat edilmelidir. Oluşturulan portföyde her bir menkul kıymetin ağırlıkları belirlenir. Belirlenen ağırlıklara göre menkul kıymetlerin getirisi ve varyansları hesaplanır. Bulunan sonuçlar doğrultusunda yatırımcı tercihleri dikkate alınarak portföy oluşturulmaktadır (Ceylan ve Korkmaz, 2000).

Hiroshi Konno ve Hiroaki Yamazaki tarafından geliştirilen Konno-Yamazaki modeli de bir diğer çeşitlendirme yöntemidir. 1991 yılında hazırladıkları makalelerinde “Markowitz’in portföy optimizasyon modelinin teorik tutarlılığının olmasına karşın bu orijinal formun karesel (quadratic) programlama gerektirdiği, karesel programlamanın ise kovaryans matrislerinin oluşturulmasında zorluklar bulunması nedeniyle büyük ölçekli portföylere uygulanmasının zor olduğunu” ileri sürmüşlerdir. Bu modelinde portföy oluşturma işlemi karesel bir problem olmaktan çıkıp doğrusal bir probleme dönüşmüştür (Yamazaki ve Konno,1991).

6. YSA İLE FİNANSIN TARİHSEL GELİŞİMİ

Yapay sinir ağlarının finans alanında kullanımı çok eski yıllara dayanmaktadır. Her geçen gün bu kullanım artarak devam etmektedir. Literatüre bakıldığında YSA'nın finans alanındaki kullanımı 1980'li yıllarda başlamıştır. Türkiye'de ise 1990'ların sonuna doğru YSA ile finansın birlikte kullanımına başlanmıştır. YSA ile risk-getiri tahmini ve optimum portföyün elde edilmesiyle ilgili çeşitli çalışmalar yapılmıştır.

1994 yılında Hill vd. YSA'nın tahmin edebilme gücünü ölçmek için yapmış oldukları çalışmalarında özellikle YSA ile yapılabilecek regresyon modelleri, karar verme yöntemleri ve zaman serileri konuları üzerinde durulmuştur. Yaptıkları çalışmalarda YSA'nın tahmin ve karar verme sürecinde en başarılı sonuçları verdiği görülmüştür (Hill vd., 1994).

Yao J. tarafından Black-Scholes opsiyon fiyatlandırma modeli ile YSA'yı hisse senedi fiyat tahmin etmek amacıyla karşılaştırmış ve bu karşılaştırma sonucunda YSA'nın daha iyi sonuçlar verdiği görülmüştür (Yao J., 2000).

Diler 'in yapmış olduğu bir çalışmada BİST-100 endeksinin bir sonraki gün hangi yönde ilerleyeceğinin tahmin edilmesi için YSA ile bir model oluşturulmuştur. Oluşturulan modelde "Hatayı Geriye Yayma Yöntemi" nin daha da güçlendirilerek kullanılmasıyla %60,81 oranında doğru tahmin sağlanmıştır (Diler, 2003).

Tektaş ve Karataş yapmış olduğu çalışmalarında 7 adet şirketin hisse senedi fiyatlarını tahmin etmek için kullandıkları haftalık ve günlük veri setlerinde korelasyon katsayısı aracılığıyla tahminler yaparak yapay sinir ağlarını ile daha başarılı sonuçlar elde edilmiştir (Tektaş ve Karataş, 2004).

Karaatlı vd. tarafından BİST-100 endeksinin kapanış fiyatını tahmin etmek için oluşturdukları modeli hem regresyonla hem de YSA ile oluşturmuş ve YSA'nın verdiği sonuçlara göre daha iyi bir performans gösterdiği görülmüştür (Karaatlı vd., 2005).

Fernandez ve Gomez tarafından Hong Kong, Almanya, İngiltere, Amerika, Japonya borsaları üzerinde yaptıkları araştırmada Hopfield tipi YSA modeli ile tavlama benzetimi algoritması (SA), tabu araştırması (TS) ve genetik algoritmayı karşılaştırmış ve portföy

seçiminde YSA'nın diğer modellere göre daha iyi sonuçlar çıkardığı görülmüştür (Fernandez ve Gomez, 2007).

Kutlu ve Badur tarafından yapılan bir çalışmada BİST-100 endeks değerinin ileri beslemeli yapay sinir ağı ile modellenebileceği ileri sürülmüştür. Endeksin hangi yönde olduğunu tahmin etmek için "Basit Hareketli Ortalamalar (BHO)" yöntemi ile işlem yapılmıştır ve diğer yöntemlere göre daha iyi bir performans gösterdiğine dikkat çekilmiştir (Kutlu ve Badur, 2009).

Freitas De Souza vd., Brezilya borsasındaki endeks üzerinde yaptıkları çalışmalarda otoregresif hareketli referans yapay sinir ağıyla endeks üzerinde %78 getiri elde edilmiştir (Freitas De Souza vd., 2009).

2009 yılında Zhang ve Wu tarafından yapılan çalışmada hisse senedi endekslerini tahmin etmek için geliştirilen modeli geri yayımlı yapay sinir ağı modeline entegre edilmiştir. Önerilen bu yeni modelin öğrenme yeteneği diğer yöntemlere göre daha iyi sonuç vermiştir (Zhang ve Wu, 2009).

Ulusoy tarafından yapılan bir araştırmada 1997-2000 yılları arasındaki İstanbul Menkul Kıymetler Borsası'nda endeks tahmini için 13 değişkenli bir ağ modeli geliştirilmiş ve oluşturulan ağ ile hata geri yayılma algoritmasıyla modellenmiştir. Siyasi bir etki olmaması durumunda kurulan modelin diğer modellere kıyasla daha başarılı sonuçlar verdiği görülmüştür. Aynı zamanda endeks değerinin ertesi gün ne olacağını tahmin edebilmenin literatüre daha çok fayda sağlayacağı kanaatine varılmıştır (Ulusoy, 2010).

Vaisla ve Bhatt piyasadaki fiyatları tahmin edebilmek için bazı istatistiksel metotlarla birlikte YSA modeli kullanmıştır. İki yöntemin sonuçları karşılaştırıldığında sinir ağı için doğru bir mimari kurulduğunda ve ağ iyi eğitildiğinde piyasa fiyatlarının çok iyi tahmin edildiği görülmüştür. İstatistiksel metotlarda ise mimarisi iyi olmasına rağmen karmaşık verileri çözümlerken zorlanacağı sonucuna varılmıştır (Vaisla ve Bhatt, 2010).

Kara ve Boyacıoğlu tarafından BİST-100 endeksinin kapanış fiyatını tahmin edebilmek için destek vektör makinaları ile YSA sonuçları karşılaştırılmış ve sonuçlarda YSA ile bulunan tahmin oranı daha yüksek çıkmıştır (Kara ve Boyacıoğlu, 2011).

Erdoğan ve Özyürek (2012), BİST-100 endeksinde yer alan beyaz eşya firmalarının günlük fiyatlarının tahmin edilebilmesi için klasik yöntemlere ek olarak YSA kullanmıştır ve tahmin sonuçlarının çok daha başarılı olduğu görülmüştür (Erdoğan ve Özyürek, 2012).

Ticknor tarafından hisse senedi getirilerinin tahmini için yaptığı araştırmada Bayes tipi YSA ve ARIMA modelini karşılaştırmıştır. Bu çalışmadaki verilerin oluşturulan modelde mevsimsellik testi veya çevrim analizine ihtiyaç duymadan iyi bir performans gösterdiği görülmüştür. Modellerin karşılaştırılmasında YSA hisse senedi getiri tahmininde oldukça başarılı olmuştur (Ticknor, 2013).

Sakarya ve Yavuz BİST-100 endeksin bir gün veya bir hafta sonraki değerlerini MLP ağını kullanarak tahmin etmeye çalışmış ve çalışmanın sonuçlarında YSA'nın daha az bir hatayla tahminde bulunduğu ortaya konulmuştur (Sakarya ve Yavuz, 2015).

Yiğiter vd. (2016) BİST' te bulunan hisse senetlerinin kapanış fiyatlarını zaman serileri kullanarak bulanık mantık, yapay sinir ağları ve regresyon yöntemleri aracılığıyla tahmin edilmiştir. Analizler sonucunda sinir ağı modelinin diğer modellere göre daha başarılı olduğu görülmüştür (Yiğiter vd., 2017).

7. REGRESYON ANALİZİ

Günlük ve bilimsel hayatta araştırmacılar tarafından en çok üzerine çalışılan konu iki olay (değişken) arasındaki ilişkinin incelenmesidir. Regresyon terimi 1886 yılında ilk kez Francis Galton tarafından kullanılmıştır (Galton, 1886). Bu yöntem bir veya birden fazla değişkenin aralarındaki ilişkiyi matematiksel olarak ifade edebilmek ve bağımlı-bağımsız değişkenler hakkında tahminlerde bulunabilmek için kullanılan bir klasik yöntemdir. Sebep- sonuç ilişkisi bulunan tüm ekonomik ve sosyal olaylarda regresyon analizine sıklıkla rastlanmaktadır (Orhunbilge, 2010).

Regresyon modellerinde değişkenler bağımlı ve bağımsız değişken olmak üzere iki grupta incelenmektedir. Bağımlı değişken, bağımsız değişkenler tarafından açıklanmaya çalışılan değişkendir. Genel olarak bağımsız değişken x ile bağımsız değişken ise Y ile gösterilmektedir. Regresyon analizi bağımsız değişken sayısına göre iki başlık altında incelenmektedir. Bunlar;

1. Tek değişkenli (basit) regresyon analizi
2. Çoklu regresyon analizi

7.1. Tek Değişkenli (Basit) Regresyon Analizi

Bağımlı ve bağımsız değişken sayısının bir adet olduğu ve bu değişkenler arasındaki ilişkiyi inceleyen modeldir. Değişkenler arasındaki doğrusal ilişkiyi ortaya koyan matematiksel bir formül ile elde edilmektedir. Bu formül bulunurken genellikle en küçük kareler yöntemi kullanılmaktadır. Eşitlik 7.1.'de basit regresyona ait denklem yer almaktadır.

$$Y_i = \alpha + \beta x_i + \varepsilon_i \quad (7.1)$$

Y_i = Bağımlı değişken

x_i = Bağımsız değişken

α = sabit

β = regresyon katsayısı

ε_i = hata katsayısı

Regresyon analizinde gözlem noktalarını temsil eden en iyi eğriyi bulma işleminde en çok kullanılan yöntem En Küçük Kareler (EKK) yöntemidir. En küçük kareler yöntemi, oluşacak hataların kareleri toplamı minimum olacak şekilde bir eğri denklemi bulma mantığına dayanır. Bu yaklaşımla bulunacak bir denklem en az hatalı ve en gerçekçi değeri verecek bir eğri denklemi olacaktır. EKK yönteminin başarılı bir şekilde uygulanabilmesi için birçok varsayım gerekmektedir. Bu varsayımları aşağıda verilen maddeler halinde sıralanabilir (Berry 1993):

- Bağımsız değişkenlerin hepsi nicel veya nitel olarak ölçülmüş olması, bağımlı değişken Y'nin ise nicel ve sürekli olması gerekmektedir.
- Tüm bağımsız değişkenlerin varyansının sıfırdan farklı olması gerekmektedir.
- Bağımsız değişkenler arasında doğrusal bir ilişkinin olmaması gerekmektedir.
- Hata terimleri ortalaması sıfırdır. $E(\varepsilon_i) = 0$
- Bağımsız değişkenler ve hata terimi arasında korelasyon olmamalıdır.
- Hata terimlerinin varyansı sabit olmalıdır. $V(\varepsilon_i) = \sigma^2$
- Hata terimleri arasında otokorelasyon olmamalıdır. $Cov(\varepsilon_i, \varepsilon_j) = 0, i \neq j$
- Hata katsayıları (ε_i), normal dağılmalıdır.

Regresyon analizinde matematiksel model kurulduktan sonra modelin yeterliliği olup olmadığı kontrol edilmektedir. Kurulan modelin gerçek modele ne kadar yaklaştığını ve regresyon analiz varsayımlarının sağlanıp sağlanmadığını kontrol etmek son derece önemli bir adımdır. Bunun için genelde varyans analizinden yararlanılmaktadır. Modelin yeterliliğinin varyans analizi ile ortaya konması yeterli değildir. Bunun dışında regresyon parametrelerinin de istatistik açıdan anlamlı olması da t testleri ile araştırılmalıdır. Çizelge 7.1'de varyans analizi formüllerine yer verilmektedir.

Çizelge 7.1. Varyans Analizi

VARYANS ANALİZİ				
Kaynaklar	Serbestlik Derecesi	Kareler Toplamı	Kareler Ortalaması	F
Regresyon	1			
Hata	n-2	$\sum (y_i - \hat{y}_i)^2$	KT/SD	RKO/HKO
Genel	n-1	$\sum (y_i - \bar{y})^2$		

$$(y_i - \bar{y}_i) = (y_i - \hat{y}_i) + (\hat{y}_i - \bar{y}) \quad (7.2)$$

$$\sum (y_i - \bar{y})^2 = \sum [(y_i - \hat{y}_i) + (\hat{y}_i - \bar{y})]^2 \quad (7.3)$$

$$\sum (y_i - \bar{y})^2 = \text{Genel Kareler Toplamı (GKT)}$$

$$\sum (y_i - \hat{y}_i)^2 = \text{Hata Kareler Toplamı (HKT)}$$

$$\sum (\hat{y}_i - \bar{y})^2 = \text{Regresyon Kareler Toplamı (RKT)}$$

$$2 \sum (y_i - \hat{y}_i)(\hat{y}_i - \bar{y}) = 0 \quad (7.4)$$

7.1.1. Belirtme Katsayısı

Belirtme katsayısı (R^2), bağımlı değişkenin bağımsız değişkeni ne oranda açıkladığını gösteren bir değerdir.

$$R^2 = \frac{\sum_{i=1}^n (\hat{y}_i - \bar{y})^2}{\sum_{i=1}^n (y_i - \bar{y})^2} = \frac{\text{RKT}}{\text{GKT}} \quad (7.5)$$

R^2 0 ile 1 arasında değer almaktadır. Bu değer 1'e yakın çıkması bağımlı değişkenin bağımsız değişkenler tarafından iyi bir oranda açıklandığını göstermektedir. Basit regresyonda tek bağımsız değişken olduğundan, bağımlı değişkendeki değişimler sadece bu değişken tarafından açıklanmaktadır.

7.2.Çoklu Regresyon Analizi

Çoklu regresyon analizinde bağımlı değişken ile birden fazla bağımsız değişken arasındaki ilişkiyi inceleyen istatistiksel bir yöntemdir. Bağımlı değişken Y ile gösterilirken, bağımsız değişken x ile gösterilmektedir. Çoklu regresyon analizinin matematiksel ifadesi eşitlik 7.6.'da yer almaktadır.

$$Y = \alpha + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_k X_k + \varepsilon_i \quad (7.6)$$

x_1, x_2, \dots, x_k : bağımsız değişkenler

$\beta_1, \beta_2, \dots, \beta_k$: regresyon katsayıları

ε_i : hata katsayısı

Çoklu regresyon analizinde bağımsız değişkenler modele dahil edilirken korelasyon katsayısı (R) ve çoklu belirtme katsayısına (R^2) bakılmaktadır. Basit regresyon modelinin sahip olduğu tüm varsayımlar çoklu regresyon modeli için de geçerlidir. Bu varsayımlara ek olarak bağımsız değişkenlerin arasında basit doğrusal ilişki bulunmamaktadır maddesi eklenebilir.

7.2.1. Çoklu Belirtme Katsayısı

Basit regresyonda olduğu gibi R^2 değeri bağımlı değişkenin bağımsız değişkenler tarafından ne oranda açıklandığını göstermektedir. Bağımlı değişkende meydana gelen değişiklikler farklı regresyon modelleri ile açıklanabilmektedir ve bu modellerin gözlem sayıları, yapıları ve değişken sayıları farklılık gösterebilmektedir. Bu nedenle çoklu regresyon modellerinde R^2 değerinin kullanımı çok uygun olmamaktadır. Çoklu regresyon modellerinde modele yeni değişken ilave edildiğinden belirlilik katsayısı değeri her zaman artmaktadır. Bu sebeple bağımlı değişkeni aynı, bağımsız değişken sayıları farklı regresyon modellerinin karşılaştırılması için düzeltilmiş belirlilik katsayısı \bar{R}^2 kullanılır (Koutsoyiannis,1989). Düzeltilmiş belirlilik katsayısının matematiksel ifadesi eşitlik 7.7.'de görüldüğü şekilde hesaplanmaktadır.

$$\bar{R}^2 = 1 - \frac{n-1}{n-k} \cdot (1 - R^2) \quad (7.7)$$

7.3. Panel Regresyon (Veri) Analizi

Ekonometrik analizde güvenli kaynaklardan veri toplamak kadar toplanan verinin kullanılacak modele uygun olacak şekilde alınması da ekonomik tahminlerin en önemli noktalarından birisidir. Ekonometrik analizde üç çeşit veri kullanılmaktadır. Bunlar;

1. *Zaman Serisi Verisi*: Değişkenlerin gün, ay, mevsim, yıl gibi zaman birimlerine göre değişimini gösteren verilerdir.
2. *Yatay Kesit Veri*: Zamanın belli bir noktasında, farklı birimlerden toplanan verilerdir. Burada “birim”; birey, hane halkı, firma, sektör; ülke gibi iktisadi birimleri ifade etmek için kullanılır.
3. *Panel Veri*: Bireyler, ülkeler, firmalar, hane halkları gibi birimlere ait yatay kesit gözlemlerinin, belli bir dönemde bir araya getirilmesi şeklinde tanımlanabilir.

Zaman serisi ve yatay dikey kesit verileri ile ayrı ayrı analizler yapılabilmektedir. Zaman boyutuna sahip kesit serilerini kullanarak ekonomik ilişkilerin tahmin edilmesi yöntemine panel veri analizi adı verilmektedir. Finansal verilerin analizinde genellikle zaman serileri ve yatay kesit verileri birlikte kullanılmaktadır. Zaman serileri ve yatay kesit verileri arasında oldukça fazla etkileşim olması nedeniyle birlikte kullanıldığında çok daha iyi sonuçlar elde edilmektedir (Tatoğlu, 2012).

Panel veri analizi çeşitli zamanlardaki aynı birimlerden veya bireylerden alınan bilgilerden oluşmaktadır. Günümüzde dinamik ekonometrik modelleri tahmin edebilmek için tercih edilmektedir (Finkel, 1995). Bu model genellikle gözlenemeyen açıklayıcı değişkenleri kontrol altında tutmak ve zaman içinde oluşabilecek değişimleri analiz etmek için iki durumda kullanılmaktadır (Petersen, 2009). Panel veri analizinin regresyon modeli eşitlik 7.8.’de yer almaktadır.

$$Y_{it} = \alpha_{it} + \beta_{it} x_{it} + \varepsilon_{it} \quad (7.8)$$

Y: Bağımlı değişken

x: Açıklayıcı değişkenler seti

β : Eğim katsayıları

α : Sabit kesişim katsayısı

ε : Hata katsayısı

i : Modeldeki yatay kesit boyutu ($i=1, \dots, N$)

t : Her birimi ait zaman serisi boyutu ($t=1, \dots, T$)

7.3.1. Panel Birim Kök Testleri

Klasik bir regresyon modelinde tüm varsayımlar bağımlı ve bağımsız değişken üzerine kurulmuştur. Bu varsayımlar değişkenlerin durağan olması, hataların sabit varyans ve sıfır ortalamalı olması gerektiğini belirtmektedir. Eğer seriler durağan değil ise ortaya çıkan regresyon modelleri sahte olabilir. Oluşan sahte regresyon modellerinin t istatistikleri anlamlı olsa bile sonuçlar yorumlandığında anlamsız sonuçlar elde edilecektir. Bu nedenle ekonomik verileri incelemeye önce doğru sonuçlar elde edebilmek için ilk olarak birim kök testlerinin uygulanması gerekmektedir. Birim kök testleri yapılarak serinin durağan olup olmadığı belirlenir ve sahte regresyon modellerinin oluşmaması için önlem alınabilir (Uçak, 2010).

Modellerin birim kök içerip içermediğini test etmekte kullanılan birçok yöntem vardır. Bunlar;

- Levin, Lin ve Chu
- Breitung
- Hadri
- Im, Peseran, Shin
- Fisher ADF

Bu testler değişkenlerin ardışık olmadığı varsayımı üzerine kurulmuştur. Literatürde kullanılan birçok birim kök testi bulunmaktadır. Bu çalışmada her bir bağımlı ve bağımsız değişken için Augmented Dickey-Fuller (ADF) ve Phillips-Perron birim kök testleri kullanılacaktır. Literatürde kullanılan birçok birim kök testi ADF testinin geliştirilmesi ile elde edilmiştir (Polat, 2014).

Durağanlık için oluşturulan hipotez testleri aşağıda belirtildiği şekildedir:

H_0 : Seride birim kök vardır.

H_1 : Seride birim kök yoktur.

Tüm birim kök testlerinde serinin durağan olup olmadığı test edilmektedir. H_1 hipotezinin kabul edilebilmesi 0,05 anlamlılık düzeyi için p değerinin 0,05'den daha küçük bir değer olması gerekmektedir.

7.3.2. Panel Regresyon Modelleri

Üç adet panel regresyon modeli bulunmaktadır.

1. Ortak Sabit Regresyon Modeli (Pooled-Havuzlanabilir Regresyon)
2. Sabit Etkiler Modeli (Fixed Effects)
3. Rassal Etkiler Modeli (Random Effects)

Ortak Sabit Regresyon Modeli:

Panel regresyon analizi yöntemleri arasında en çok kullanılan havuzlanabilir regresyon modelidir. Verilerin kesit ya da zaman boyutu göz ardı edilerek en küçük kareler tahmin edicisi ile tahmin yapılmaktadır. En küçük kareler tahmin edicisi kullanılarak doğru sonuçlar elde edebilmek için hata değerleri ile bağımsız değişkenler arasında bir ilişki olmamalıdır (Dağlı vd., 2015).

Bu modelde bütün yatay birimlerin homojen olduğu varsayılmaktadır. Yatay birimler arasında herhangi bir heterojenlik bulunmamaktadır. En küçük kareler yöntemi sabit terim (α) ve eğim katsayısı (β) için tutarlı ve etkin tahminler sağlamaktadır (Yıldırım, 2009).

Havuzlanabilir regresyon modelinin matematiksel gösterimi eşitlik 7.9.'da verilmiştir.

$$y_{it} = \alpha + \sum_{k=1}^K \beta_k x_{kit} + \varepsilon_{it} \quad i=1,2,\dots,N ; t=1,2,\dots,T. \quad (7.9)$$

Sabit Etkiler Modeli (Fixed Effects):

Bu model hem modelin sabit terimindeki deęişimleri hem de birimlerin hareketlerindeki deęişimleri göstermektedir. Sabit etkiler modelinde bulunan her bir yatay kesit deęişkeni için eğim katsayılarının aynı olması ve sabit katsayılarının farklı olması bireysel etkilerin görülebilmesini sağlamaktadır. Modelde bulunan sabit katsayısı birimlere göre deęişkenlik gösterirken zamana göre sabittir. Modelde bulunan eğim katsayıları ise hem kesit için hem de zaman için aynı kalmaktadır (Gömlüksiz ve Alagöz, 2012).

Sabit etkiler modelinin matematiksel gösterini eşitlik 7.10.'da yer almaktadır.

$$Y_{it} = \alpha_i + \beta x_{it} + \varepsilon_{it} \quad (7.10)$$

$$i = 1 \dots N, \quad t = 1 \dots T, \quad E(\varepsilon_{it}) = 0, \quad \text{Cov}(\varepsilon_{it}) = 0, \quad \text{Var}(\varepsilon_{it}) = \sigma_\varepsilon^2 \quad \text{ve} \quad E(X_{it}, \varepsilon_{it}) = 0$$

Y_{it} = Bağımlı deęişken

x_{it} = Açıklayıcı deęişken vektörü

ε_{it} = Hata katsayısı

β = Eğim katsayısı

α_i = Sabit terim

Rassal Etkiler Modeli (Random Effects):

Panel regresyon modelleri arasında üçüncü yöntem de Rassal etkiler modelidir. Bu model tesadüfi etkiler modeli olarak da bilinmektedir. Bu yöntem sabit etkiler modelinin alternatifi olarak ortaya çıkmıştır. Bu modeller her birime ve zamana ait katsayıların olmadığı ve bağımsız rasgele deęişkenlerin kullanıldığı modellerdir. Tesadüfi etkiler modelinde birim etki sabit olmadığından sabit parametre içerisinde deęil, tesadüfi olduğundan hata payı içerisinde yer alır (Tatoęlu, 2014).

Rassal etkiler modelinin matematiksel gösterimi Eşitlik 7.11.'da yer almaktadır.

$$Y_{it} = \beta_{1i} + \beta_{2i} x_{2it} + \beta_{3i} x_{3it} + \varepsilon_{it} \quad \beta_{1j} \neq \beta_{1i} + \mu_i \quad (7.11)$$

8. UYGULAMA

Son yıllarda finans alanında yapılan bilimsel çalışmaların büyük bir kısmı menkul kıymetlerin veya menkul kıymetlerden oluşan çeşitli portföylerin gelecekteki fiyatlarını tahmin etmek üzerine yoğunlaşmıştır. Bu doğrultuda çalışmanın amacı da öncelikle BİST-30 endeksinden seçilen hisse senetlerinin çoklu doğrusal regresyon analizi ve yapay sinir ağları kullanılarak hisse senedinin fiyatlarının tahmin edilmesi ve sonrasında da risk değerleri hesaplanarak sonuçların karşılaştırılmasıdır.

Çalışmada BİST-30 endeksinden rasgele olarak seçilen 12 adet hisse senedi ele alınmıştır. Bu hisse senetleri ile eşit ağırlıklı ve rasgele seçilen 3 adet portföy oluşturulmuştur. Hisse senetlerinin 2019-2020 yıllarını kapsayan 3'er aylık dönemler için kapanış fiyatları incelenmiştir.

Şirketlerin bilançolarında açıklamış olduğu toplam varlıklar, öz sermaye (öz kaynaklar), borçlar, net dönem karı ve lot sayısı (ödenmiş sermaye) kullanılarak elde edilen finansal göstergeler çalışmada kullanılmıştır.

BİST-30'da işlem gören hisse senetlerinin getirileri için 5 adet finansal gösterge incelenmiştir. Bunlar;

1. Piyasa Değeri/ Defter Değeri (PD/DD)
2. Hisse Başına Kar (HBK)
3. Öz Sermaye Karlılığı (ÖSK)
4. Kaldıraç Oranı (KO)
5. Fiyat/ Kazanç Oranı (F/K)

8.1.Çalışmada Kullanılacak Değişkenler

Kullanılacak değişkenler çizelge 8.1.'de verilmiştir.

Çizelge 8.1. Bağımlı ve Bağımsız Değişkenler

Bağımsız Değişkenler	Bağımlı Değişken
Piyasa Değeri/Defter Değeri	Hisse Senedi Kapanış Fiyatı
Hisse Başına Kar	
Öz Sermaye Karlılığı	
Kaldıraç Oranı	
Fiyat/Kazanç Oranı	

8.1.1. Bağımlı Değişken

Çalışmada bağımlı değişken olarak <https://tr.investing.com/> sitesinden hisse senetlerinin kapanış fiyatları alınmıştır.

8.1.2. Bağımsız Değişkenler

Piyasa değeri/ defter değeri, hisse başına kar, öz sermaye karlılığı, kaldıraç oranı ve fiyat/kazanç oranından oluşan 5 adet bağımsız değişken şirketlerin bilançolarında yer alan bilgiler doğrultusunda hesaplanmıştır. Veriler www.isyatirim.com.tr adresinden temin edilmiştir.

Piyasa değeri/Defter değeri oranı (PD/DD):

Bu oran bir hisse senedinin piyasa fiyatı ile muhasebe değerini karşılaştırmak için kullanılmaktadır. Yatırımcılar için şirket değerlemesindeki önemli ölçülerden birisidir. Yatırımcılar Pd/dd oranı 1'den küçük olan şirketlere yatırım yapmayı tercih etmektedirler. Pd/dd değeri iki farklı formülle bulunmaktadır.

1. $PD/DD = \text{Hisse Senedi Fiyatı} / \text{Hisse Başı Defter Değeri}$
2. $PD/DD = \text{Toplam Piyasa Değeri} / \text{Öz sermaye}$

Hisse başına kar (HBK):

Bir işletmenin hisse değerinin ölçülmesinde yatırımcılar tarafından oldukça önemsenen bir orandır ve hisse başına elde edilen karı göstermektedir. Hisse başına karın yüksek olması her zaman olumlu karşılanmakla beraber yalnız başına bu orana bakarak yatırım kararı almak doğru olmayabilir.

$\text{Hisse Başına Kar} = \text{Net Kar} / \text{Toplam Hisse Adedi}$

Öz sermaye karlılığı (ÖSK):

İşletme ortaklarının koydukları sermaye karşılığında ne kadar kar elde ettiklerini gösteren değerdir. Önemli bir karlılık göstergesi olan bu değer aynı zamanda bir yönetim performansı göstergesidir. Bu değer yüksek olması işletme kaynaklarının verimli kullanıldığını göstermektedir.

$\text{Öz Sermaye Karlılığı} = \text{Net Kar} / \text{Öz Sermaye}$

Kaldıraç oranı (KO):

Bu değer varlıkların ne kadarının borçlar ile finanse edildiğini göstermektedir. Şirketin yüksek borca sahip olması ödeme riskini artıracığı için bu oranın düşük olması tercih edilir.

Kaldıraç Oranı = Toplam Borçlar/Toplam Varlıklar

Fiyat/Kazanç oranı (F/K):

Şirketlerin mali performans yönünden karşılaştırarak yatırım kararı verme sürecinde kolaylık sağlayan bir orandır. Genellikle F/K oranı düşük olan hisse senetlerinin seçilmesi daha başarılı sonuçlar verir. Ama tam tersi durumunda sonuç veren hisse senetleri de bulunmaktadır. Bu nedenle sadece F/K bakarak seçim yapmak doğru değildir.

Fiyat Kazanç Oranı = Hisse Fiyatı/Hisse Başına Kar

8.2.Çalışmada Kullanılan Hisse Senetleri

Çalışmada BİST-30 endeksi arasında yer alan savunma, metal ana sanayi, metalik cevher üretimi, mali kuruluşlar, toptan-perakende, haberleşme, yatırım ve metal eşya imalatı sektörleri seçilmiştir.

Çizelge 8.2. Hisse Senetleri ve Sektörler

SEKTÖRLER	ŞİRKET
Savunma	ASELS
Metal Ana Sanayi	EREGL
Metalik Cevher Üretimi	KOZAA
Toptan ve Perakende	BIMAS
Haberleşme	TCELL, TTKOM
Yatırım	DOHOL
Metal Eşya İmalat	ARCLK
Mali Kuruluşlar	TKFEN, KCHOL, SAHOL, SISE

Çizelge 8.3’de rasgele olarak oluşturulan 3 adet portföy yer almaktadır.

Çizelge 8.3. Portföylerin Dağılımı

Portföy 1	Portföy 2	Portföy 3
ASELS	BIMAS	SAHOL
EREGL	TCELL	TKFEN
KOZAA	DOHOL	TTKOM
SISE	ARCLK	KCHOL

8.3.Panel Regresyon Analizi

Bir zaman serisinde model geliştirmeden önce serilerin ortalama ve varyansının sabit olup olmadığını kontrol etmek gerekmektedir. Diğer bir ifadeyle durağanlığına bakılmaktadır. Serilerin durağanlığını kontrol edebilmek için birim kök testleri kullanılmaktadır. Birim köke sahip verilerle istatistiksel analiz gerçekleştirildiğinde yanıtıcı regresyon sonuçlar elde edilebilmektedir. Eğer seride birim kök olduğu sonucuna varılırsa logaritmik dönüşüm yapılarak birinci farklarının alınması gerekmektedir. Serilerde birim kök olup olmadığına bakmak için Eviews 11. Paket programı kullanılmıştır. Literatürde yaygın olarak kullanılan Fisher ADF birim kök testi uygulanmıştır.

Çizelge 8.4. Fisher ADF Birim Kök Testi Sonuçları

Değişkenler	Katsayı	Std. Hata	T-istatistik	p
Hisse Senedi Fiyatı	-0.480261	0.132257	-3.631282	0.0007
PD/DD	-1.274800	0.144914	-8.796921	0.0000
HBK	-0.943311	0.150757	-6.257163	0.0000
ÖSK	-0.827177	0.147245	-5.617677	0.0000
KO	-0.443326	0.162422	-5.53132	0.0000
F/K	-0.535212	0.131459	-5.45223	0.0000

Bağımlı ve bağımsız değişkenlerin durağanlık testi için yokluk ve sıfır hipotezi aşağıdaki gibi belirtilir:

H₀: Seride genel birim kök vardır.

H₁: Seride genel birim kök yoktur.

Çizelge 8.4’de değişkenlerin durağanlığı incelenmiştir. Değişkenlerin p olasılık değerleri incelendiğinde $p < 0,05$ olması nedeni ile H₀ hipotezi red edilmiştir. Veri seti içerisinde birim kök bulunmamaktadır.

Panel Veri Analizinde, sabit etkiler modeli ile rassal etkiler modeli arasındaki seçimi yapabilmek için Hausman testini kullanılmıştır. Hausman testi; birim etki dolayısıyla hata terimi ile açıklayıcı değişkenler arasında korelasyon olup olmadığını belirlemeye çalışmaktadır. Böylelikle rassal etkili modelin uygun olup olmadığını ölçmektedir.

H₀: Rassal etkiler vardır.

H₁: Rassal etkiler yoktur.

Çizelge 8.5. Hausman Testi Sonuçları

Model	Ki-Kare testi	p
Yatay Kesit Rassal Etkisi	3,3231	0,424

Çizelge 8.5.’de yer alan Hausman testi sonuçların $p < 0,05$ olması nedeni ile H₀ hipotezi kabul edilir. Serilerin rassal etkiler modeline sahip olduğu söylenebilir. Diğer bir ifadeyle hata terimi ile açıklayıcı değişkenler arasında korelasyon bulunmaktadır.

Çizelge 8.6. Rassal Etkiler Modeli Sonuçları

	B	Std. Hata	Beta	T	p
(Sabit)	4,145	1,477		5,775	,000
PD/DD	12,263	,737	,856	16,629	,000
HBK	11,491	,648	,936	17,739	,000
ÖSK	134,674	12,692	,734	10,611	,000
KO	4,943	2,171	,080	2,277	,026
F/K	,019	,031	,025	,608	,545
p	0,000				
F	64,545				
R ²	0,917				

Çizelge 8.6.'de Piyasa Değeri/Defter Değeri (PD/DD), Hisse Başına Kar (HBK), Öz Sermaye Karlılığı (ÖSK), Kaldıraç Oranı (KO) ve Fiyat/Kazanç oranı (F/K) değişkenlerinin hisse senedi kapanış fiyatı üzerindeki etkisi rassal etkiler modeli ile tahmin edilmiştir. Analiz sonucuna göre F/K oranı portföy getirisi üzerinde anlamlı bir etki yapmadığı anlaşılmaktadır ($p>0,05$). KO, PD/DD, ÖSK ve HBK'nin istatistiksel olarak anlamlı olduğu ve bu değişkenlerin modele pozitif bir etki sağladığı söylenebilir. Hisse senedi fiyatındaki değişikliklerin %91,7'si çalışmada kullanılan değişkenler ile açıklanmaktadır.

8.4.Klasik Çoklu Regresyon Analizi Kullanarak Portföy Değerlendirmesi

Regresyon analizinin uygulamasında bağımlı değişken ve 5 tane bağımsız değişken kullanılmıştır. Regresyon analizi yapılarak oluşturulan model ile hisse senedi kapanış fiyatı tahmininde bulunulmuştur. Regresyon analizini yapmak için Eviews 11. paket programından yararlanılmıştır. Rasgele olarak oluşturulan 3 portföy için regresyon analizi sonuçları elde edilerek sonuçlar yorumlanmıştır. Regresyon modelini oluşturmadan önce normal dağılıma uygunluk, çoklu bağlantı, değişen varyanslık ve otokorelasyon sorunlarının olmaması varsayımlarının sağlanıp sağlanmadığı araştırılmıştır.

8.4.1. Normal Dağılıma Uygunluk

Veri setinin normal dağılıma uygun olup olmadığını kontrol etmek için Eviews 11. paket programında Jarque-Bera testi uygulanmıştır. Normal dağılıma uygunluğu test etmek için kullanılan yokluk hipotezi ve seçenек hipotezi aşağıdaki gibi belirtilmiştir:

H_0 : ϵ hata katsayıları normal dağılıma uygundur.

H_1 : ϵ hata katsayıları normal dağılıma uygun değildir.

Jarque-Bera test istatistiği serinin normal dağılıma sahip olup olmadığını göstermektedir

ve $JB = \frac{T-k}{6} \left[S^2 + \frac{(K-3)^2}{4} \right]$ formülüyle hesaplanmaktadır.

T: Örneklem Büyüklüğü

S: Çarpıklık Katsayısı

K: Basıklık Katsayısı

k: Değişken Sayısı

Bu test istatistiği X_2 dağılımına sahiptir. $JB < 5.99$ veya $p > 0,05$ ise veriler normal dağılmaktadır.

Çizelge 8.7.'de portföylerin normal dağılıma uygunluğuna bakıldığında her bir portföyünde $p > 0,05$ olması ve $JB < 5,99$ nedeni ile normal dağılım varsayımını sağladığı görülmektedir.

Çizelge 8.7. Jarque- Bera Testi

Portföyler	Jarque-Bera	p
Portföy 1	0,44	0,8
Portföy 2	0,82	0,66
Portföy 3	0,23	0,88

Çizelge 8.8.Portföylere İlişkin Özet İstatistikler

	Portföy 1	Portföy 2	Portföy 3
Ortalama	8,64e-16	5,38e-16	1,07e-17
Ortanca	0.103	0,015	-1,43
Maksimum	2,19	0,43	9,4
Minimum	-2,41	-0,38	-4,51
Std. Sapma	1,01	0,21	3,28
Çarpıklık	-0,05	0,07	1,05
Basıklık	2,79	2,22	3,37

8.4.2. Çoklu Doğrusal Bağımlılığın Sınanması

VIF (Varyans Şişkinlik Faktörü) değişkenler arasında çoklu bağlantı olup olmadığını kontrol ederken kullanılmaktadır. Bu değer 10'dan büyük ise regresyon katsayılarının varyansını da büyütür ve yorum yaparken yanlış sonuçlar elde edilmesine neden olur (Özdamar, 2011).

- ◆ VIF =1 çoklu doğrusal bağımlılık yoktur
- ◆ $1 < VIF \leq 5$ orta düzeyde çoklu bağımlılık vardır. Verilere göre oynamalar yapılabilir
- ◆ $5 < VIF \leq 10$ çoklu doğrusal bağımlılık vardır. Değişkenlerde düzeltmeler yapılmalı ve çoklu bağımlılığa sebep olan değişkenler çıkarılmalıdır.
- ◆ VIF > 10 yüksek bir düzeyde çoklu bağımlılık vardır. Model direk geçersiz sayılmaktadır.

Çizelge 8.9. VIF Değerleri

Bağımsız Değişkenler	VIF		
	Portföy 1	Portföy 2	Portföy 3
Hisse Başına Kar	13,42	7,88	4,06
Fiyat/Kazanç Oranı	1,67	3,95	1,17
Kaldıraç Oranı	1,63	2,99	1,22
Öz Sermaye Karlılığı	15,33	14,31	5,36
Piyasa Değeri/Defter Değeri Oranı	1,36	5,02	3,27

Çizelge 8.9.'de yer alan bağımsız değişkenlerin VIF değerleri arasında 10'dan büyük değerler bulunmaktadır. Bu durum değişkenler arasında çoklu bağlantı sorunu olduğuna bir işarettir. Çoklu bağlantı sorununu giderebilmek için verilere dönüşüm yapılmış ve logaritmaları alınmıştır. Portföy 1'de bulunan veriler arasındaki çoklu bağlantı sorununu çözebilmek için hem birbirleriyle yüksek bir korelasyona sahip olan hem de VIF değerleri 10'dan büyük olan hisse başına kar ve öz sermaye karlılığı değişkenleri çalışmadan çıkarılmıştır. Portföy 2'de seriler arasında çoklu doğrusal bağımlılığı bulunması nedeni ile dönüşüm yapılarak model yeniden kurulmuştur. Portföy 3'de ise VIF değerleri 10'dan küçük olması nedeni ile çoklu bağlantı problemi bulunmamaktadır. Kurulan yeni regresyon modelleri için VIF değerleri çizelge 8.10.'da yer almaktadır.

Çizelge 8.10. VIF Değerleri (Düzeltilmiş)

Bağımsız Değişkenler	VIF	
	Portföy 1	Portföy 2
Fiyat/Kazanç Oranı	1,1	1,34
Kaldıraç Oranı	1,11	1,61
Piyasa Değeri/Defter Değeri Oranı	1,11	1,33

8.4.3. Otokorelasyonun Sınanması

Otokorelasyonun sınanmasında yaygın olarak kullanılan Durbin-Watson testi, hata terimleri arasında otokorelasyonun var olup olmadığını belirlemektedir. Eğer seri otokorelasyona sahip ise regresyon katsayılarının varyansları çok düşük çıkar ve önemi etkiye sahip olmayan açıklayıcı değişkenler önemi etkiye sahip gibi değerlendirilebilir (Özdamar 2011).

Durbin Watson testi sonrasında bulunan katsayılar değişkenlerin sayısına göre belirlenen teorik dağılımının D_α kritik değerine göre belirlenen üst (d_U) ve alt (d_L) sınır değerlerine göre değerlendirilir.

H_0 : Otokorelasyon yoktur

H_1 : Negatif veya pozitif otokorelasyon vardır.

Pozitif Otokorelasyon	Yorum Yok	Otokorelasyon Yok	Yorum Yok	Negatif Otokorelasyon	
0	d_L	d_U	$4-d_U$	$4-d_L$	4

Çizelge 8.11.'de dönüşüm yapılmadan önceki modellere ilişkin Durbin Watson testi sonuçları yer almaktadır.

Çizelge 8.11. Durbin Watson Test Sonuçları

Portföyler	Durbin-Watson Katsayısı	d_L Tablo Değeri	d_U Tablo Değeri	Durbin Watson Bölgesi
Portföy 1	1,08	1,109	1,819	Pozitif otokorelasyon bölgesi
Portföy 2	0,82	1,109	1,819	Pozitif otokorelasyon bölgesi
Portföy 3	0,94	1,109	1,819	Pozitif otokorelasyon bölgesi

Otokorelasyon sorununu çözebilmek için verilere logaritmik dönüşüm uygulanmış ve birinci farkları alınmıştır. Otokorelasyon sorununu çözüldükten sonra bulunan Durbin-Watson test istatistiği sonuçları çizelge 8.12.'de yer almaktadır.

Çizelge 8.12. Durbin Watson Test Sonuçları (Düzeltilmiş)

Portföyler	Durbin-Watson Katsayısı	d _L Tablo Değeri	d _U Tablo Değeri	Durbin Watson Bölgesi
Portföy 1	1,27	1,109	1,819	Otokorelasyon yok
Portföy 2	1,32	1,109	1,819	Otokorelasyon yok
Portföy 3	1,81	1,109	1,819	Otokorelasyon yok

8.4.4. Değişen Varyanslık

Literatürde değişen varyans problemini saptamada kullanılan birçok istatistik testi bulunmaktadır. Bu çalışmada yaygın olarak kullanılan White testinden yararlanılmıştır.

Çizelge 8.13. White Testi

Portföyler	White Testi
Portföy 1	0,3036
Portföy 2	0,058
Portföy 3	0,29

Çizelge 8.13.'deki sonuçlar incelendiğinde $p > 0,05$ olması nedeni ile serilerde değişen varyanslık problemi bulunmamaktadır.

Çalışmada kullanılan hisse senetlerinin finansal oranları çizelge 8.14.'da görülmektedir.

Çizelge 8.14. Çalışmada Kullanılan Finansal Oranların Değerleri

Hisse	Dönem	Hisse Fiyatı	PD/DD	HBK	ÖSK	KO	F/K
ASELS	2019 3 ay	9,69	1,02	0,55	0,06	0,47	17,55
ASELS	2019 6 ay	9,26	0,93	1,17	0,12	0,46	7,92
ASELS	2019 9 ay	9,39	0,89	1,73	0,16	0,46	5,42
ASELS	2019 12 ay	12,15	1,02	2,93	0,25	0,47	4,15
ASELS	2020 3 ay	16,06	1,26	0,81	0,06	0,45	19,90
ASELS	2020 6 ay	17,85	1,35	1,62	0,12	0,44	11,05
ASELS	2020 9 ay	17,11	1,20	2,62	0,18	0,44	6,53
ASELS	2020 12 ay	17,30	3,90	0,25	0,47	4,43	1,09
EREGL	2019 3 ay	7,50	0,28	0,04	0,40	26,34	0,96
EREGL	2019 6 ay	6,78	0,66	0,08	0,32	10,30	0,81
EREGL	2019 9 ay	6,64	0,88	0,10	0,32	7,52	0,78
EREGL	2019 12 ay	9,16	0,95	0,11	0,33	9,67	1,03
EREGL	2020 3 ay	7,95	0,09	0,01	0,33	92,61	0,81
EREGL	2020 6 ay	8,02	0,25	0,02	0,34	32,34	0,76
EREGL	2020 9 ay	9,83	0,41	0,03	0,33	23,73	0,83

EREGL	2020 12 ay	16,82	0,95	0,08	0,29	17,79	1,43
KOZAA	2019 3 ay	5,56	0,40	0,03	0,10	13,83	0,47
KOZAA	2019 6 ay	7,47	0,89	0,07	0,09	8,37	0,57
KOZAA	2019 9 ay	8,62	1,48	0,10	0,09	5,82	0,60
KOZAA	2019 12 ay	12,59	2,05	0,13	0,09	6,14	0,81
KOZAA	2020 3 ay	12,46	0,40	0,02	0,10	31,41	0,75
KOZAA	2020 6 ay	14,54	0,92	0,05	0,10	15,85	0,82
KOZAA	2020 9 ay	13,25	1,48	0,08	0,10	8,94	0,69
KOZAA	2020 12 ay	16,25	1,80	0,09	0,10	9,02	0,81
SISE	2019 3 ay	5,56	0,20	0,03	0,48	27,90	0,73
SISE	2019 6 ay	5,03	0,41	0,05	0,49	12,19	0,63
SISE	2019 9 ay	4,46	0,60	0,08	0,50	7,38	0,56
SISE	2019 12 ay	5,38	0,85	0,10	0,51	6,36	0,63
SISE	2020 3 ay	4,87	0,20	0,02	0,52	24,80	0,57
SISE	2020 6 ay	6,25	0,23	0,03	0,50	26,71	0,70
SISE	2020 9 ay	6,75	0,62	0,06	0,50	10,91	0,69
SISE	2020 12 ay	7,72	0,95	0,10	0,49	8,12	0,77
BIMAS	2019 3 ay	38,72	0,71	0,06	0,71	54,58	3,14
BIMAS	2019 6 ay	45,86	1,85	0,17	0,74	24,76	4,13
BIMAS	2019 9 ay	48,16	2,98	0,22	0,73	16,13	3,61
BIMAS	2019 12 ay	48,24	4,03	0,29	0,72	11,96	3,46
BIMAS	2020 3 ay	52,50	1,42	0,09	0,75	37,03	3,41
BIMAS	2020 6 ay	68,00	3,71	0,22	0,74	18,31	4,09
BIMAS	2020 9 ay	71,70	5,87	0,33	0,74	12,22	4,05
BIMAS	2020 12 ay	69,05	8,59	0,36	0,69	8,04	2,92
TCELL	2019 3 ay	12,66	0,56	0,07	0,63	22,75	1,63
TCELL	2019 6 ay	13,55	0,77	0,10	0,62	17,64	1,72
TCELL	2019 9 ay	12,50	1,13	0,14	0,62	11,04	1,58
TCELL	2019 12 ay	14,76	1,48	0,18	0,60	10,00	1,80
TCELL	2020 3 ay	13,86	0,40	0,05	0,59	34,94	1,63
TCELL	2020 6 ay	15,64	0,78	0,09	0,58	19,95	1,76
TCELL	2020 9 ay	15,80	1,33	0,14	0,61	11,84	1,71
TCELL	2020 12 ay	16,71	1,93	0,20	0,60	8,68	1,77
DOHOL	2019 3 ay	1,02	0,09	0,03	0,40	11,60	0,37
DOHOL	2019 6 ay	1,26	0,17	0,06	0,36	7,30	0,45
DOHOL	2019 9 ay	1,75	0,17	0,06	0,35	10,19	0,62
DOHOL	2019 12 ay	1,68	0,24	0,08	0,32	7,13	0,58
DOHOL	2020 3 ay	1,92	0,12	0,04	0,31	15,66	0,64
DOHOL	2020 6 ay	2,05	0,23	0,07	0,29	9,11	0,65
DOHOL	2020 9 ay	2,60	0,54	0,15	0,33	4,78	0,73
DOHOL	2020 12 ay	3,40	0,53	0,15	0,32	6,40	0,95
ARCLK	2019 3 ay	17,51	0,33	0,03	0,72	52,49	1,35
ARCLK	2019 6 ay	21,10	0,66	0,05	0,73	32,08	1,56
ARCLK	2019 9 ay	18,00	1,01	0,07	0,72	17,76	1,33
ARCLK	2019 12 ay	21,82	1,37	0,09	0,72	15,94	1,50

ARCLK	2020 3 ay	15,82	0,38	0,03	0,72	41,80	1,07
ARCLK	2020 6 ay	22,24	0,98	0,06	0,71	22,69	1,38
ARCLK	2020 9 ay	28,54	2,49	0,13	0,71	11,45	1,49
ARCLK	2020 12 ay	35,74	4,21	0,20	0,70	8,48	1,72
SAHOL	2019 3 ay	7,17	0,52	0,02	0,86	13,84	0,25
SAHOL	2019 6 ay	9,35	0,95	0,03	0,85	9,80	0,31
SAHOL	2019 9 ay	8,42	1,42	0,05	0,84	5,93	0,27
SAHOL	2019 12 ay	9,48	1,85	0,06	0,84	5,12	0,29
SAHOL	2020 3 ay	8,28	0,58	0,02	0,85	14,16	0,26
SAHOL	2020 6 ay	8,06	1,09	0,03	0,85	7,38	0,23
SAHOL	2020 9 ay	9,01	1,88	0,05	0,86	4,79	0,25
SAHOL	2020 12 ay	10,92	2,34	0,06	0,85	4,67	0,29
TKFEN	2019 3 ay	25,64	2,11	0,16	0,64	12,13	1,95
TKFEN	2019 6 ay	23,62	3,19	0,23	0,59	7,39	1,69
TKFEN	2019 9 ay	17,71	3,89	0,27	0,56	4,55	1,22
TKFEN	2019 12 ay	18,56	3,84	0,26	0,57	4,83	1,25
TKFEN	2020 3 ay	14,30	0,13	0,01	0,57	112,43	0,98
TKFEN	2020 6 ay	16,44	0,39	0,03	0,55	41,88	1,07
TKFEN	2020 9 ay	15,30	0,35	0,02	0,57	43,33	0,91
TKFEN	2020 12 ay	17,55	-0,16	-0,01	0,58	-108,00	1,12
TTKOM	2019 3 ay	3,90	0,09	0,04	0,81	44,04	1,73
TTKOM	2019 6 ay	5,56	0,21	0,09	0,79	26,13	2,44
TTKOM	2019 9 ay	5,79	0,53	0,21	0,77	10,88	2,26
TTKOM	2019 12 ay	8,01	0,69	0,25	0,76	11,65	2,97
TTKOM	2020 3 ay	7,37	0,19	0,07	0,76	39,04	2,59
TTKOM	2020 6 ay	7,40	0,47	0,15	0,74	15,78	2,42
TTKOM	2020 9 ay	6,68	0,59	0,19	0,76	11,28	2,18
TTKOM	2020 12 ay	7,93	0,91	0,26	0,73	8,73	2,31
KCHOL	2019 3 ay	15,30	0,31	0,02	0,70	49,79	0,88
KCHOL	2019 6 ay	18,00	0,87	0,05	0,69	20,70	0,98
KCHOL	2019 9 ay	19,86	1,29	0,07	0,68	15,35	1,06
KCHOL	2019 12 ay	19,47	1,73	0,09	0,67	11,24	0,99
KCHOL	2020 3 ay	15,15	1,37	0,05	0,86	11,07	0,51
KCHOL	2020 6 ay	15,31	1,75	0,06	0,86	8,76	0,50
KCHOL	2020 9 ay	15,09	2,66	0,08	0,87	5,68	0,46
KCHOL	2020 12 ay	23,50	12,68	0,36	0,86	1,85	0,68

Portföy 1

Oluşturulan ilk portföy ASELS, EREGL, KOZAA ve SISE hisse senetlerinden oluşmaktadır. Çizelge 8.15.'de regresyon analizi sonuçları verilmiştir.

Çizelge 8.15. Portföy 1 için Regresyon Analizi Sonuçları

Değişkenler	Katsayılar	Std. Hata	t-ist.	p
F/K	-0,0019	0,0018	-1,0509	0,3023
KO	-0,3476	0,0464	-7,4812	0.0000
PD/DD	1,458	0,1158	12,5849	0.0000
C	2,1153	0,0699	30,2417	0.0000
R ²	0,86	F-ist.	58,5001	0.0000
Düzeltilmiş R ²	0,84			
Tahminin Std. Hatası	0,1648			

En Küçük Kareler (EKK) yöntemi ile tahmin edilmiş ve verilerin analizinde Eviews 11. paket programı kullanılmıştır. Modelde, hisse senedi kapanış fiyatları bağımlı değişken, Fiyat/Kazanç oranı, kaldıraç oranı, piyasa değeri/defter değeri, öz sermaye karlılığı ve hisse başına kar bağımsız değişkenler olarak ele alınmıştır. ÖSK ile HBK modelden çıkarılarak regresyon modeli oluşturulmuştur. Bunun nedeni çoklu bağlantı probleminin olması ve değişkenler arasında yüksek korelasyonun bulunmasıdır. Verilerin logaritmaları alınarak dönüşüm yapıldıktan sonra model oluşturulmuştur. Model için kritik değer 0,05 olarak alınıp işlem yapılmıştır. Kurulan model ve sonuçları çizelge 8.15.'de yer almaktadır.

R², bağımsız değişkenlerin bağımlı değişkeni açıklama gücünü göstermektedir. R² değerinin yüksek olması, bağımsız değişkenlerin bağımlı değişkeni açıklama gücünün yüksek olduğunu gösterir. R² değerinin 0,862408 bulunması, bağımsız değişkenlerin bağımlı değişkenin %86'sını açıklayabildiğini göstermektedir. F istatistik değerinin kritik değer olan 0.05'ten küçük olması modelin bir bütün olarak anlamlı olduğunu ifade etmektedir. PD/DD istatistiksel olarak anlamlı ve pozitif bir etkiye sahip olduğu görülmektedir. Eşitlik 8.1.'de hisse senedi fiyatı tahmini için oluşturulan model yer almaktadır.

$$\text{Hisse senedi fiyatı} = 2,11 + 1,45 * (\text{PD/DD}) - 0,34 * (\text{KO}) \quad (8.1)$$

Çizelge 8.16. Korelasyon Değerleri

Model	HF	F/K	KO	PD/DD
HF	1	-0,1306	-0,2664	0,7581
F/K	-0,1306	1	0,0609	-0,0246
KO	-0,2664	0,0609	1	0,3137
PD/DD	0,7581	-0,0246	0,3137	1

Çizelge 8.16.'de değişkenlerin birbirleriyle olan ilişkileri yer almaktadır. Korelasyon matrisine göre değişkenler arasındaki ilişkileri yorumlayabiliriz. Örnek olarak hisse senedi fiyatı ile PDD/DD arasında 0,75'lik bir ilişki bulunmaktadır.

Portföy 2

Oluşturulan ikinci portföy BIMAS, TCELL, DOHOL ve ARCLK hisse senetlerinden oluşmaktadır. Çizelge 8.17.'de regresyon analizi sonuçları verilmiştir.

Çizelge 8.17. Portföy 2 için Regresyon Analizi Sonuçları

Değişkenler	Katsayılar	Std. Hata	t-ist.	p
F/K	-0,147	0,0801	-1,8337	0,0773
KO	1,9392	0,2386	8,1272	0.0000
PD/DD	1,1083	0,1043	10,6218	0.0000
C	3,6274	0,3321	10,9209	0.0000
R ²	0,972	F-ist.	324,3464	0.0000
Düzeltilmiş R ²	0,969			
Tahminin Std. Hatası	0,2257			

Modelde, hisse senedi kapanış fiyatları bağımlı değişken, Fiyat/Kazanç oranı, kaldıraç oranı, piyasa değeri/defter değeri, öz sermaye karlılığı ve hisse başına kar bağımsız değişkenler olarak ele alınmıştır. ÖSK ile HBK modelden çıkarılarak regresyon modeli oluşturulmuştur. Bunun nedeni çoklu bağlantı probleminin olması ve değişkenler arasında yüksek korelasyonun bulunmasıdır. Verilerin logaritmaları alınarak dönüşüm yapıldıktan sonra model oluşturulmuştur. Model için kritik değer 0,05 olarak alınıp işlem yapılmıştır. Kurulan model ve sonuçları Çizelge 8.17.'de yer almaktadır.

R² değerinin 0,972 bulunması, bağımsız değişkenlerin bağımlı değişkenin %97'sini açıklayabildiğini göstermektedir. F istatistik değerinin kritik değer olan 0.05'ten küçük olması modelin bir bütün olarak anlamlı olduğunu ifade etmektedir. PD/DD ve KO istatistiksel olarak anlamlı ve pozitif bir etkiye sahip olduğu görülmektedir. F/K oranının

ise istatiksels olarak anlamlı olmadığı görülmektedir. F/K oranının istatiksels olarak anlamsız olması nedeni ile modele dahil edilmemiştir. Eşitlik 8.2.'de hisse senedi fiyatı tahmini için oluşturulan model yer almaktadır.

$$\text{Hisse senedi fiyatı} = 3,62 + 1,10 * (\text{PD/DD}) + 1,93 * (\text{KO}) \quad (8.2)$$

Çizelge 8.18. Korelasyon Değerleri

Model	HF	F/K	KO	PD/DD
HF	1	0,4332	0,9194	0,9485
F/K	0,4332	1	0,5763	0,3796
KO	0,9194	0,5763	1	0,8052
PD/DD	0,9485	0,3796	0,8052	1

Çizelge 8.18.'da hisse senedi fiyatı ile KO arasında 0,91'lik bir ilişki bulunmaktadır.

Portföy 3

Oluşturulan üçüncü portföy SAHOL, TKFEN, TTKOM ve KCHOL hisse senetlerinden oluşmaktadır. Çizelge 8.19.'de regresyon analizi sonuçları verilmiştir..

Çizelge 8.19. Portföy 3 için Regresyon Analizi Sonuçları

Değişkenler	Katsayılar	Std. Hata	t-ist.	p
F/K	0,0174	0,0083	2,0887	0,0463
KO	-2,7138	0,5569	-4,8726	0.0000
PD/DD	-0,0071	0,1074	-0,0664	0,9475
C	0,04	0,0409	0,9805	0,3355
R2	0,6769	F-ist.	18,8562	0.0000
Düzeltilmiş R2	0,641			
Tahminin Std. Hatası	0,2273			

Oluşturulan modelde, hisse senedi kapanış fiyatları bağımlı değişken, Fiyat/Kazanç oranı, kaldıraç oranı, piyasa değeri/defter değeri, öz sermaye karlılığı ve hisse başına kar bağımsız değişkenler olarak ele alınmıştır. Öz sermaye karlılığı ile hisse başına kar modelden çıkarılarak regresyon modeli oluşturulmuştur. Bunun nedeni değişkenler arasında yüksek korelasyonun bulunmasıdır. Verilerin logaritmaları alınarak dönüşüm yapılmış ve sonrasında birinci farkları alınarak model oluşturulmuştur. Model için kritik

değer 0,05 olarak alınıp işlem yapılmıştır. Kurulan model ve sonuçları çizelge 8.19.'de yer almaktadır.

R^2 değerinin 0,679 bulunması, bağımsız değişkenlerin bağımlı değişkenin %67'sini açıklayabildiğini göstermektedir. F istatistik değerinin kritik değer olan 0.05'ten küçük olması modelin bir bütün olarak anlamlı olduğunu ifade etmektedir. PD/DD $p > 0,05$ olması nedeni ile istatistiksel olarak anlamlı değildir. Bu nedenle PD/DD çıkarılarak regresyon modeli oluşturulmuştur. KO ve F/K oranının istatistiksel olarak anlamlı bulunmuştur. F/K oranı pozitif yönlü bir etkiye sahipken kaldıraç oranı negatif yönlü bir etki sağlamaktadır. Eşitlik 8.3.'de hisse senedi fiyatı tahmini için oluşturulan model yer almaktadır.

$$\text{Hisse senedi fiyatı} = 0,04 + 0,017*(F/K) - 2,71*(KO) \quad (8.3)$$

Çizelge 8.20. Korelasyon Değerleri

Model	HF	F/K	KO	PD/DD
HF	1	0,5526	-0,786	0,2497
F/K	0,5526	1	-0,4232	-0,0813
KO	-0,786	-0,4232	1	-0,4129
PD/DD	0,2497	-0,0813	-0,4129	1

Çizelge 8.20.'de hisse senedi fiyatı ile F/K oranı arasında 0,55'lik bir ilişki bulunmaktadır.

Çizelge 8.21. Regresyon Tahmini ile Hisse Senedi Fiyatları

Portföy 1				
Hisse	Dönem	Gerçek Fiyat(Y)	Kestirim(\hat{Y})	Artık Değerleri
ASELS	2019 3 ay	2,271	2,379	-0,108
ASELS	2019 6 ay	2,23	2,262	-0,036
ASELS	2019 9 ay	2,24	2,206	0,034
ASELS	2019 12 ay	2,50	2,399	0,098
ASELS	2020 3 ay	2,78	2,697	0,079
ASELS	2020 6 ay	2,88	2,815	0,067
ASELS	2020 9 ay	2,84	2,653	0,187
ASELS	2020 12 ay	2,85	2,495	0,356
EREGL	2020 12 ay	2,01	2,329	-0,314
EREGL	2019 3 ay	1,91	2,181	-0,267
EREGL	2019 6 ay	1,89	2,14	-0,247
EREGL	2019 9 ay	2,21	2,519	-0,304
EREGL	2019 12 ay	2,07	2,01	0,063
EREGL	2020 3 ay	2,08	2,038	0,044
EREGL	2020 6 ay	2,29	2,187	0,098
EREGL	2020 12 ay	2,82	3,03	-0,207
KOZAA	2020 9 ay	1,72	1,783	-0,067
KOZAA	2020 12 ay	2,01	2,119	-0,108
KOZAA	2019 3 ay	2,15	2,198	-0,044
KOZAA	2019 6 ay	2,53	2,61	-0,077
KOZAA	2019 9 ay	2,52	2,444	0,079
KOZAA	2019 12 ay	2,68	2,608	0,069
KOZAA	2020 3 ay	2,58	2,37	0,214
KOZAA	2020 12 ay	2,79	2,589	0,199
SISE	2020 6 ay	1,72	1,86	-0,144
SISE	2020 9 ay	1,62	1,655	-0,040
SISE	2020 12 ay	1,50	1,485	0,010
SISE	2019 3 ay	1,68	1,672	0,011
SISE	2019 6 ay	1,58	1,467	0,116
SISE	2019 9 ay	1,83	1,777	0,056
SISE	2019 12 ay	1,91	1,781	0,129
SISE	2020 12 ay	2,044	1,969	0,075

Çizelge 8.21.'e portföy için hesaplanan kestirim değerleri ve modelin artık değerleri yer almaktadır. Y ile \hat{Y} değerlerini karşılaştırıldığında gerçek hisse senedi kapanış fiyatlarına yakın değerler tahmin edildiği görülmektedir.

Çizelge 8.22. Regresyon Tahmini ile Hisse Senedi Fiyatları

Portföy 2				
Hisse	Dönem	Gerçek Fiyat(Y)	Kestirim(\hat{Y})	Artık Değerleri
BIMAS	2019 3 ay	3,656	3,636	0,020
BIMAS	2019 6 ay	3,826	4,156	-0,330
BIMAS	2019 9 ay	3,875	4,026	-0,151
BIMAS	2019 12 ay	3,876	4,002	-0,126
BIMAS	2020 3 ay	3,961	3,892	0,069
BIMAS	2020 6 ay	4,220	4,165	0,055
BIMAS	2020 9 ay	4,272	4,232	0,040
BIMAS	2020 12 ay	4,235	3,8	0,435
TCELL	2020 12 ay	2,538	2,809	-0,271
TCELL	2019 3 ay	2,606	2,879	-0,273
TCELL	2019 6 ay	2,526	2,843	-0,317
TCELL	2019 9 ay	2,692	2,961	-0,269
TCELL	2019 12 ay	2,629	2,618	0,011
TCELL	2020 3 ay	2,750	2,773	-0,023
TCELL	2020 6 ay	2,760	2,89	-0,130
TCELL	2020 12 ay	2,816	2,939	-0,123
DOHOL	2020 9 ay	0,020	0,402	-0,382
DOHOL	2020 12 ay	0,231	0,439	-0,208
DOHOL	2019 3 ay	0,560	0,689	-0,129
DOHOL	2019 6 ay	0,519	0,524	-0,005
DOHOL	2019 9 ay	0,652	0,467	0,185
DOHOL	2019 12 ay	0,718	0,397	0,321
DOHOL	2020 3 ay	0,956	0,875	0,081
DOHOL	2020 12 ay	1,224	1,056	0,168
ARCLK	2020 6 ay	2,863	2,743	0,120
ARCLK	2020 9 ay	3,049	2,989	0,060
ARCLK	2020 12 ay	2,890	2,888	0,002
ARCLK	2019 3 ay	3,083	3,027	0,056
ARCLK	2019 6 ay	2,761	2,523	0,238
ARCLK	2019 9 ay	3,102	2,858	0,244
ARCLK	2019 12 ay	3,351	3,061	0,290
ARCLK	2020 12 ay	3,576	3,22	0,356

Çizelge 8.22.'de portföy için hesaplanan kestirim değerleri ve modelin artık değerleri yer almaktadır. Y ile \hat{Y} değerlerini karşılaştırıldığında gerçek hisse senedi kapanış fiyatlarına yakın değerler tahmin edildiği görülmektedir.

Çizelge 8.23. Regresyon Tahmini ile Hisse Senedi Fiyatları

Portföy 3				
Hisse	Dönem	Gerçek Fiyat(Y)	Kestirim(\hat{Y})	Artık Değerleri
SAHOL	2019 3 ay	NA	NA	NA
SAHOL	2019 6 ay	0,265	0,062	0,203
SAHOL	2019 9 ay	-0,104	0,047	-0,151
SAHOL	2019 12 ay	0,118	0,051	0,067
SAHOL	2020 3 ay	-0,135	0,013	-0,148
SAHOL	2020 6 ay	-0,026	0,034	-0,06
SAHOL	2020 9 ay	0,111	0,009	0,102
SAHOL	2020 12 ay	0,192	0,068	0,124
TKFEN	2020 12 ay	0,853	0,815	0,038
TKFEN	2019 3 ay	-0,082	0,264	-0,346
TKFEN	2019 6 ay	-0,287	0,154	-0,441
TKFEN	2019 9 ay	0,046	0,01	0,036
TKFEN	2019 12 ay	-0,026	0,059	-0,085
TKFEN	2020 3 ay	0,139	0,123	0,016
TKFEN	2020 6 ay	-0,071	-0,06	-0,011
TKFEN	2020 12 ay	0,137	0,384	-0,247
TTKOM	2020 9 ay	-1,504	-1,227	-0,277
TTKOM	2020 12 ay	0,354	0,089	0,265
TTKOM	2019 3 ay	0,04	0,103	-0,063
TTKOM	2019 6 ay	0,324	0,046	0,278
TTKOM	2019 9 ay	-0,083	0,057	-0,14
TTKOM	2019 12 ay	0,004	0,098	-0,094
TTKOM	2020 3 ay	-0,102	-0,023	-0,079
TTKOM	2020 12 ay	0,171	0,142	0,029
KCHOL	2020 6 ay	0,657	0,211	0,446
KCHOL	2020 9 ay	0,162	0,059	0,103
KCHOL	2020 12 ay	0,098	0,075	0,023
KCHOL	2019 3 ay	-0,019	0,053	-0,072
KCHOL	2019 6 ay	-0,25	-0,635	0,385
KCHOL	2019 9 ay	0,01	0,0359	-0,0259
KCHOL	2019 12 ay	-0,014	0,021	-0,035
KCHOL	2020 12 ay	0,442	0,039	0,403

Çizelge 8.23.'de portföy için hesaplanan kestirim değerleri ve modelin artık değerleri yer almaktadır. Y ile \hat{Y} değerlerini karşılaştırıldığında gerçek hisse senedi kapanış fiyatlarına yakın değerler tahmin edildiği görülmektedir

Çizelge 8.24. Performans Ölçütleri

Portföy	N	R2	HKO	HKOK	OMH	OMYH
Portföy 1	32	0,86	0,024	0,001	0,123	0,056
Portföy 2	32	0,97	0,119	0,014	0,457	6,462
Portföy 3	31	0,67	0,042	0,002	0,155	1,802

N: Hisse senedi sayısı, R2: Düzeltmiş belirleme katsayısı, HKO: Hata kareler ortalaması, HKOK: Hata kareler ortalamasının karakökü, OMH: Ortalama mutlak sapma, OMYH: Ortalama mutlak yüzde hata

Çizelge 8.24.'de rasgele olarak oluşturulan her bir portföy için performans göstergeleri yer almaktadır. Bu göstergelerin minimum olması tercih edilir. Sonuçlar incelendiğinde minimum değerlere sahip olan portföy 3 olarak görülmektedir.

8.5.YSA ile Portföy Değerlendirmesi

Analizde kullanılmak üzere 6 adet değişken bulunmaktadır. Bu değişkenlerin bir kısmını hisse senedi fiyatlarını oluştururken bir kısmını finansal oranlar oluşturmaktadır. Değişkenleri analiz edebilmek için Matlab'ın fonksiyonları arasında yer alan Neural Fitting Tool kullanılmıştır. Matlaba verileri girmeden önce normalizasyon işlemi yapılmıştır. Bu işlemi yapılarak veriler eğitime hazır bir hale gelmektedir. Eğer eğitim ham veri setine uygulanırsa süreç oldukça yavaş ilerleyebilir. Normalizasyon işlemi için birçok teknik bulunmaktadır. Bu çalışmada min-max normalizasyonu yapılmıştır. Bu yöntem verileri 0 ile 1 arasındaki değerlere indirgemektedir. Min-max normalizasyonu formül eşitlik 8.4.'de verilmektedir.

$$\hat{x} = \frac{x_i - x_{\min}}{x_{\max} - x_{\min}} \quad (8.4)$$

\hat{x} = Normalize edilmiş veri,

x_i = Girdi değeri,

x_{\min} = Veride bulunan en küçük değer

x_{\max} = Veride bulunan en büyük değer

İlk olarak Matlab'a girdi ve çıktı değişkenlerini tanımlanması gerekmektedir. 5 adet girdi değişkeni ve 1 adet çıktı değişkeni bulunmaktadır.

Girdi olarak,

- PD/DD,
- HBK,
- ÖSK,
- KO,
- F/K.

Çıktı olarak ise

- Hisse senedi fiyatları

tanımlanmaktadır.

Portföy 1

Sinir ağı girdi ve çıktı verilerine göre eğitilecektir. Eğitim fonksiyonu (train network) olarak sinir ağlarının öğrenmesinde literatürde yaygın olarak kullanılan Levenberg-Marquardt backpropagation (trainlm) kullanılmıştır. Çizelge 8.25.'de de görüldüğü gibi 15 tane YSA mimarisi denenmiştir ve gizli katmanda 10 nöron bulunan modelin en iyi sonucu verdiği görülmüştür. Ağı eğitim kümesi için tüm verilerin %70, test kümesi için ise %30 oranında veri kullanılmıştır. Hisse senedi fiyatları tahmin edildikten sonra test kümesi üzerinden performans karşılaştırmaları yapılmıştır.

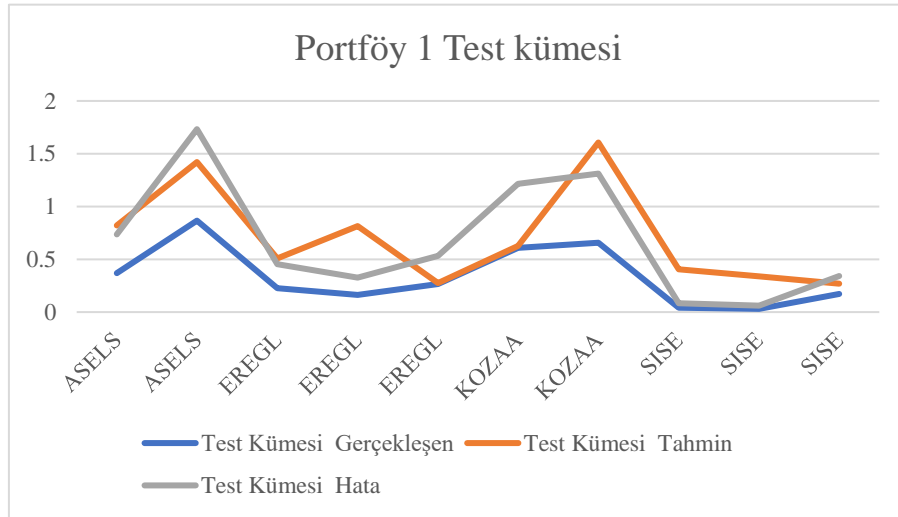
Çizelge 8.25. Gizli Katmandaki Nöron Sayılarına göre Model Karşılaştırması

Nöron Sayıları	R (Eğitim)	R(Test)	HKO
1	0,91	0,87	0,017
2	0,84	0,99	0,037
3	0,98	0,99	0,003
4	0,87	0,99	0,022
5	0,95	0,85	0,009
6	0,98	0,40	0,007
7	0,88	0,95	0,012
8	0,83	0,99	0,041
9	0,99	0,99	0,003
10	0,99	0,98	0,002
11	0,98	0,99	0,003
12	0,99	0,99	0,006
13	0,94	0,87	0,008
14	0,80	0,96	0,134
15	0,96	0,87	0,248

Portföy 1’de bulunan 32 adet hisse senedinin 22 tanesi eğitim için kalan 10 hisse senedi ise test için kullanılmıştır. YSA performansları HKO kullanılarak karşılaştırılmıştır. HKO, ağın tahmin ettiği değerler ile gerçek çıktı arasındaki farkın kareleri toplamıdır. YSA’da amaç bu değeri minimize etmektir. Bu değer 0 ya da 0 yakın olmalıdır ki hata oranları da düşük çıksın. R değerleri çıktı ile tahmin edilen değer arasındaki korelasyonu göstermektedir. Çizelge 8.25’de R(Eğitim) eğitim verileri arasındaki korelasyonu, R(Test) test verileri arasındaki korelasyonu göstermektedir. Bu değer 1’e yakın olması beklenir. Bu değer 1’e yakın veya 1 ise aralarındaki ilişkini iyi olduğu söylenebilir. Çizelge 8.25’de bulunan gizli katmanda 10 nöron bulunan model için R (eğitim) 0,99 ve R (test) 0,98 bulunmuştur Sonuçların 1 yakın olduğu görülmektedir.

Çizelge 8.26. YSA Sonucu Bulunan Test kümesinin Tahmini Değerleri ile Gerçek

Değerlerinin Karşılaştırılması			
Test Kümesi			
Hisse Senetleri	Gerçekleşen	Tahmin	Hata
ASELS	0,368	0,4512	-0,083
ASELS	0,866	0,554	0,311
EREGL	0,227	0,281	-0,054
EREGL	0,162	0,651	-0,489
EREGL	0,265	0,008	0,257
KOZAA	0,607	0,018	0,589
KOZAA	0,656	0,949	-0,293
SISE	0,042	0,362	-0,319
SISE	0,030	0,306	-0,276
SISE	0,171	0,098	0,072



Şekil 8.1. Portföy 1 için Test Kümesi Karşılaştırması

YSA performans karşılaştırması yapabilmek için OMH, HKO, HKOK ve OMYH kriterleri incelenmiştir. Bu değerlerin minimum olması istenir. Portföy 1 için OMH 0,27 , HKO 0,10 , HKOH 0,01 ve OMYH 0,03 bulunmuştur.

Portföy 2

Portföy 2 oluşturulurken 32 adet hisse senedinin 22 tanesi eğitim kümesi için kalan 10 veri ise test kümesi için kullanılmıştır. Gizli katmandaki nöron sayısını seçebilmek için 15 tane YSA mimarisi incelenmiştir. YSA performansları HKO değeri kullanılarak karşılaştırılmıştır. Bu mimariler arasında HKO en düşük olan model en iyi sonuçları vereceği için gizli katmandan 9 nöron bulunan model seçilmiştir. Çizelge 8.27.'de bu alternatifler yer almaktadır. 9 nöronlu mimarinin R(Eğitim) değeri 0,96, R(Test) değeri ise 0,99 bulunmuştur. Bu değer 1'e yakın olması beklenir. Bu değer 1'e yakın veya 1 ise aralarındaki ilişkinin iyi olduğu söylenebilir.


Çizelge 8.27. Gizli Katmandaki Nöron Sayılarına göre Model Karşılaştırması

Nöron	R (Eğitim)	R (Test)	HKO
1	0,93	0,82	0,011
2	0,96	0,93	0,004
3	0,94	0,99	0,012
4	0,78	0,95	0,042
5	0,94	0,99	0,048
6	0,94	0,99	0,009
7	0,73	0,97	0,053
8	0,96	0,82	0,009
9	0,96	0,99	0,008
10	0,90	0,99	0,016
11	0,99	0,96	0,018
12	0,90	0,99	0,020
13	0,96	0,99	0,016
14	0,99	0,92	0,161
15	0,95	0,83	0,012

Çizelge 8.28.'de YSA sonu bulunan hisse senedi fiyatları ile gerçekleşen hisse senedi fiyatlarının karşılaştırılması yer almaktadır.

Çizelge 8.28. YSA Sonucu Bulunan Test Kümesinin Tahmini Değerler ile Gerçek Değerlerin Karşılaştırılması

Hisse Senetleri	Test Kümesi		
	Gerçekleşen	Tahmin	Hata
BIMAS	0,666	0,925	-0,258
BIMAS	0,947	0,871	0,076
TCELL	0,177	0,213	-0,035
TCELL	0,181	0,387	-0,205
TCELL	0,206	0,004	0,201
DOHOL	0,003	0,258	-0,254
DOHOL	0,022	0,143	-0,121
ARCLK	0,284	0,021	0,262
ARCLK	0,294	0,400	-0,106
ARCLK	0,389	0,221	0,168



Şekil 8.2. Portföy 2 için Test Kümesi Karşılaştırması

YSA performans karşılaştırması yapabilmek için OMH, HKO, HKOK ve OMYH kriterleri incelenmiştir. Bu değerlerin minimum olması istenir. Portföy 2 için OMH 0,17, HKO 0,03 , HKOH 0,001 ve OMYH 0,02 bulunmuştur

Portföy 3

Portföy 3 oluşturulurken de 32 adet hisse senedinin 22 tanesi eğitim seti için 10 tanesi ise test kümesi için kullanılmıştır. Gizli katmandaki nöron sayısını seçebilmek için 15 tane YSA mimarisi incelenmiştir. YSA performansları HKO değeri kullanılarak karşılaştırılmıştır. Bu mimariler arasında HKO en düşük olan model en iyi sonuçları vereceği için gizli katmandan 10 nöron bulunan model seçilmiştir. Çizelge 8.29.'de bu alternatifler yer almaktadır. 10 nöronlu mimarinin R(Eğitim) değeri 0,91, R(Test) değeri ise 0,99 bulunmuştur. Bu değer 1'e yakın olması beklenir. Bu değer 1'e yakın veya 1 ise aralarındaki ilişkinin iyi olduğu söylenebilir.

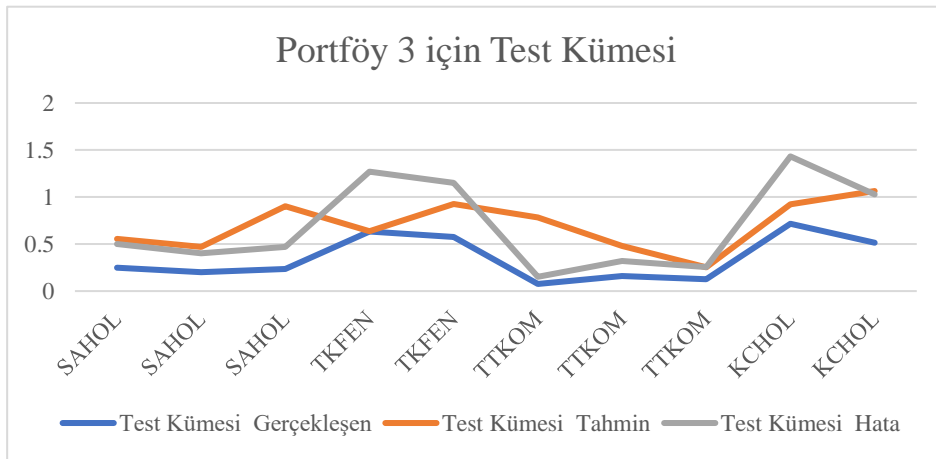
Çizelge 8.29. Gizli Katmandaki Nöron Sayılarına göre Model Karşılaştırması

Nöron	R (Eğitim)	R (Test)	HKO
1	0,38	0,54	0,053
2	0,74	0,72	0,081
3	0,88	0,25	0,022
4	0,85	0,71	0,252
5	0,22	0,41	0,183
6	0,96	0,97	0,006
7	0,89	0,99	0,014
8	0,90	0,98	0,017
9	0,85	0,99	0,023
10	0,91	0,99	0,001
11	0,95	0,99	0,007
12	0,98	0,97	0,008
13	0,89	0,89	0,019
14	0,80	0,99	0,037
15	0,99	0,98	0,003

Çizelge 8.30.'de YSA sonu bulunan hisse senedi fiyatları ile gerçekleşen hisse senedi fiyatlarının karşılaştırılması yer almaktadır

Çizelge 8.30. YSA Sonucu Bulunan Test Kümesinin Tahmini Değerler ile Gerçek Değerlerin Karşılaştırılması

Hisse Senetleri	Test Kümesi		
	Gerçekleşen	Tahmin	Hata
SAHOL	0,250	0,306	-0,056
SAHOL	0,201	0,268	-0,066
SAHOL	0,235	0,666	-0,431
TKFEN	0,635	0,001	0,635
TKFEN	0,576	0,350	0,226
TTKOM	0,076	0,708	-0,632
TTKOM	0,159	0,322	-0,162
TTKOM	0,127	0,126	0,001
KCHOL	0,716	0,208	0,508
KCHOL	0,514	0,550	-0,036



Şekil 8.3.Portföy 3 için Test Kümesi Karşılaştırması

YSA performans karşılaştırması yapabilmek için OMH, HKO, HKOK ve OMYH kriterleri incelenmiştir. Bu değerlerin minimum olması istenir. Portföy 3 için OMH 0,27 ,HKO 0,13 , HKOH 0,017 ve OMYH 0,027 bulunmuştur.

9. SONUÇ VE ÖNERİLER

Yapay sinir ağıları, klasik yöntemlere kıyasla birçok alanda çok daha başarılı sonuçlar vermektedir. Klasik yöntemler kullanılırken birçok varsayım dikkate alınmaktadır. Bu varsayımların sağlanamaması durumunda elde edilen modele olan güvenirlilikte azalmaktadır.

Daha önceki başlıklarda da sıkça belirtildiği gibi, YSA'nın finans alanındaki kullanımları oldukça fazladır. Gelişen teknoloji ile birlikte dünyanın her yerinde her geçen gün bu kullanım artmaktadır. Bu çalışmada da amaç bundan sonraki yapılacak olan çalışmalar için YSA'nın kullanımıyla daha iyi sonuçlar elde edilmesini sağlamaktır. YSA finansal piyasalarda yatırım yapmayı düşünen yatırımcılar açısından oldukça büyük bir önem teşkil etmektedir.

Çalışmanın 2,3 ve 4.bölümlerinde yapay sinir ağıları detaylı bir şekilde incelenmiştir. Aynı şekilde 5. bölümde portföy analizi detaylı olarak ele alındıktan sonra uygulama bölümüne geçilmiştir. BİST-30 yer alan 12 adet hisse senedi seçilerek 3 farklı portföy oluşturulmuştur. Oluşturulun bu 3 portföye çoklu regresyon analizi ve yapay sinir ağıının uygulanabilirliği test edilmiş ve çıkan sonuçlar karşılaştırılmıştır. Bulunan sonuçlar doğrultusunda BİST'de bulunan şirketlerin hisselerine yatırım yapmayı düşünen yatırımcıya hisse seçimi için alternatifler gösterilmiştir. Analizler yapılırken bağımlı 5 adet bağımsız değişken kullanılmıştır. Bağımlı değişkeni hisse senedi fiyatları oluştururken, 5 bağımsız değişken Piyasa Değeri/Defter Değeri, Hisse Başına Kar, Kaldıraç Oranı, Öz Sermaye Karlılığı ve Fiyat/Kazanç oranından oluşmaktadır. Günümüzde finans alanında bu değişkenlerin sadece birine ya da birkaçına bakılarak yatırım kararı verilebilmektedir. Bağımlı ve bağımsız değişkenler elde edilirken şirketlerin mali tabloları ve bilançolarından yararlanılmıştır.

İlk olarak çalışmada kullanılan bağımlı ve bağımsız değişkenlerin her biri için Eviews 11. programında birim kök olup olmadığı kontrol edilmiştir. Bağımlı ve bağımsız değişkenlerden oluşan serilerde birim kök olmadığı diğer bir ifadeyle serilerin durağan olduğu sonucuna varılmıştır. Panel veri analizinin yapılmasının nedeni hem yatay kesit hem de zaman serisi verisi olmasıdır. Sabit etkili ve Rassal etkili modellerden hangisine sahip olduğuna karar verebilmek için Hausman testi yapılmıştır. Test sonuçlarında p değeri 0,05'ten küçük olduğu için rassal etkiler modelinin seçilmesine karar verilmiştir.

Rassal etkiler modeli sonucunda bulunan R^2 değeri 0,917'dir yani hisse senedi fiyatlarındaki değişikliklerin %91,7'si çalışmada kullanılan değişkenler ile açıklanmaktadır.

Serilerin durağanlığı test edildikten sonra oluşturulan portföylere Eviews 11. paket programı yardımıyla çoklu regresyon analizi yapılmıştır. Bu analizde hata kareler ortalaması, R^2 (belirlilik katsayısı), Durbin Watson katsayısı, normal dağılım sınanması, VIF (Varyans Şişkinlik Faktörü) ve değişen varyans varsayımları incelenmiş ve yorumlanmıştır. Varsayımlara uymayan seriler için logaritmik dönüşüm yapılarak varsayımlar sağlatılmıştır. Varsayımlar sağlatıldıktan sonra regresyon modelleri kurulmuş ve hisse senedi kapanış fiyatları tahmin edilmiştir. Bu fiyat tahminleri doğrultusunda portföylerin getiri ve riskleri hesaplanmıştır. Fiyat tahmini ve getiri-risk hesaplaması işlemleri yapay sinir ağları ile de gerçekleştirilmiştir. Sinir ağı oluşturulurken verinin %70 eğitim kümesi için, %30'u test kümesi için kullanılmıştır. Ağın eğitimi için sinir ağlarının öğrenmesinde yaygın olarak kullanılan Levenberg-Marquardt backpropagation (trainlm) kullanılmıştır. Analiz tamamlandıktan sonra elde edilen sonuçlar test kümesi üzerinden yorumlanmıştır. Her iki yöntemle de performans ölçütlerini karşılaştırabilmek için HKO, HKOK, OMYH ve OMH değerleri hesaplanmıştır.

Çizelge 8.31. Performans Göstergeleri

	Yapay Sinir Ağları				Çoklu Regresyon			
	OMH	HKO	HKOK	OMYH	OMH	HKO	HKOK	OMYH
Portföy 1	0,27	0,10	0,01	0,03	0,194	0,200	0,04	0,055
Portföy 2	0,17	0,03	0,001	0,02	0,457	0,118	0,01	6,462
Portföy 3	0,27	0,13	0,017	0,027	0,154	0,041	0,001	1,801

Çizelge 8.36.'de yer alan performans kriterleri incelendiğinde bu değerler modelde oluşan hata üzerinden hesaplanmaktadır. Bu değerler ne kadar düşükse oluşan hatanın o kadar minimize edildiğini söylenebilir. Portföy 1 performans kriterlerine bakıldığında genellikle YSA ile en düşük hata elde edilmesine rağmen OMH göstergesi ile çoklu regresyon analizinde çok daha düşük hata elde edilmiştir. Portföy 1'in getiri-risk çizelgesindeki değerlere bakıldığında YSA ile tahmin sonuçlarının daha başarılı olduğu söylenebilir. Portföy 2'nin performans kriterlerinde YSA ile tahmin yapıldığında minimum hata elde edilmektedir. Portföy 3 için genel olarak çoklu regresyon analizinde minimum hata elde edilirken OMYH değerinde YSA ile minimum hata elde edilmiştir.

Yapay sinir ađları ile R^2 deđerleri incelediđinde üç portföyünde %99 iken, çoklu regresyonla Portföy 1 %86, Portföy 2 %97 ve Portföy 3 %67 olduđu görölmektedir. R^2 deđerleri üzerinden bir karşılaştırma yapılırsa eđer yapay sinir ađlarının daha başarılı olduđu söylenebilir.

Çalışmanın temel amacı uluslararası sermaye piyasalarına birer ulusal piyasa kimliđi kazandırdığı günümüz dünyasında, başarılı öngörüler yapmak suretiyle getiri sağlamak ve risklerden korunmak isteyen yatırımcılara hisse senedi fiyat tahminine yönelik bir YSA model önerisi önermektir. Finans piyasalarında bir getiri elde etmeyi hedefleyen yatırımcı için yapay zekanın altında incelenen yapay sinir ađları büyük bir önem taşımaktadır. Yatırımcılar için yapacakları yatırımları bu çerçevede inceleyerek karar vermeleri önerilmektedir.

10.KAYNAKLAR

- Akay, A., Yapay Sinir Ağları ile İmkb-100 Endeksi Gelecek Değer Öngörüsü, Karadeniz Teknik Üniversitesi Sosyal Bilimler Enstitüsü, Yüksek Lisans Tezi, Trabzon, 2009.
- Akgüç, Ö., Finansal Yönetim, 6. Baskı, Muhasebe Enstitüsü Yayıncılık, 1994.
- Aladağ, Ç.H., Eğrioğlu, E., Günay, S., Yapay Sinir Ağları ile Türkiye Elektrik Tüketiminin Tahmini, TÜİK 16. İstatistik Araştırma Sempozyumu Bildiriler Kitabı, 2007.
- Alkan, A., Sinir Ağları ve Genetik Algoritmalar ile Tahmine Dayalı Veri Madenciliği, Doktora Tezi, İTÜ, İstanbul, 2001.
- Altınırnak, S., Süre Temelli Portföyler ve İMKB’de Uygulanabilirliği, S.P.K. Yayınları, İstanbul, 2003.
- Anderson, D. ve McNeil, G., Artificial Neural Networks Technology, Kaman Science Corporation, 1992.
- Aydın, H., İ., Sosyal Sermaye- Ekonomik Kalkınma İlişkisi Avrupa Birliği Ülkeleri Üzerine Panel Regresyon Analizi, Doktora Tezi, Gaziosmanpaşa Üniversitesi Sosyal Bilimler Enstitüsü, Tokat, 2015.
- Baş, N., Yapay Sinir Ağları Yaklaşımı ve Bir Uygulama, Yüksek Lisans Tezi, Mimar Sinan Güzel Sanatlar Üniversitesi Fen Bilimleri Enstitüsü, İstanbul, 2006.
- Bayır, F. Yapay Sinir Ağları ve Tahmin Modellemesi Üzerine Bir Uygulama, Yüksek Lisans Tezi, İstanbul Üniversitesi Sosyal Bilimler Enstitüsü, İstanbul, 2006.
- Bayramoğlu, M. F., Finansal Endekslerin Öngörüsünde Yapay Sinir Ağı Modellerinin Kullanılması: İMKB Ulusal 100 Endeksinin Gün İçi En Yüksek ve En Düşük Değerlerinin Öngörüsü Üzerine Bir Uygulama, Yüksek Lisans Tezi, Karaelmas Üniversitesi Sosyal Bilimler Enstitüsü, Zonguldak, 2007.

- Bekçiođlu, S., Portföy Yaklaşımları ve Markowitz Portföy Yaklaşımının Türk Pay Senedi Piyasasına Uygulanması, Ankara, 1984.
- Bekçi İ., Optimal Portföy Oluşturulmasında Bulanık Doğrusal Programlama Modeli ve İMKB’de Bir Uygulama, Doktora Tezi, Süleyman Demirel Üniversitesi Sosyal Bilimler Enstitüsü, Isparta, 2001.
- Berry, W.D., Understanding Regresyon Assumptions, SAGE Publications, America, 1993.
- Bilginođlu, M. A., Maraş, G., Avrupa Birliđi ve Türkiye’de Mali Saydamlığın Panel Veri Yöntemi ile Analizi, Cilt: 11, Özel Sayı, 2011.
- Bolak, M., Sermaye Piyasası Menkul Kıymetler ve Portföy Analizi, Beta Yayınları, İstanbul, 1994.
- Cartwright, H.M., Artificial Neural Networks: Methods and Applications, Humana Press, 2009.
- Ceylan A., Korkmaz T., Sermaye Piyasası ve Menkul Deđer Analizi, Ekin Kitabevi, Bursa, 2000.
- Ceylan, A. ve Korkmaz, T., Borsada Uygulamalı Portföy Yönetimi, Ekin Kitabevi, Bursa, 1995.
- Çelebi, D., Bayraktar, D., An Integrated Neural Network and Data Envelopment Analysis for Supplier Evaluation Under Incomplete Information, Expert Systems with Applications, 35, 2008.
- Çelik, E., Gayrimenkul Yatırım Ortalıklarında Piyasa Deđer ve Aktif Kârlılıđı Etkileyen Finansal Oranların Panel Veri Analizi Yöntemiyle Belirlenmesi, İstanbul Teknik Üniversitesi Fen Bilimler Enstitüsü, Yüksek Lisans Tezi, İstanbul, 2020.
- Çetinceli, K., Doğrusal Programlama ile Portföy Optimizasyonu ve İMKB-30 Endeksi Üzerine Uygulanması, Süleyman Demirel Üniversitesi Sosyal Bilimler Enstitüsü, Isparta, 2012.

- Dađlı, H., Karakaya, A., Bulut, E., Emeklilik yatırım Fonlarının Karakteristik Özellikleri ve Performansı: Türkiye Örneđi, Uluslararası İktisadi ve İdari İncelemeler Dergisi, Yıl: 7, Sayı: 14, 2015.
- Dađlı, H., Sermaye Piyasası ve Portföy Analizi, Derya Kitabevi, Trabzon, 2004.
- Davalo, E., Naim, P., Neural Networks, Macmillan Education, 1991.
- Demirelli, Y., Yapay Zekâ Yöntemleri ile Karşılaştırmalı Portföy Optimizasyonu ve İmkb Üzerine Bir Uygulama, Doktora Tezi, Süleyman Demirel Üniversitesi Sosyal Bilimler Enstitüsü, İstanbul, 2014.
- Diler, A.İ., İMKB Ulusal 100 Endeksinin Yönünün Yapay Sinir Ağları Hata Geri Yayma Yöntemi ile Tahmin Edilmesi, İMKB Dergisi, Vol. 25, 2003.
- Dođan, G., Yapay Sinir Ağları Kullanılarak Türkiye'deki Özel Bir Sigorta Şirketinde Portföy Deđerlendirmesi, Hacettepe Üniversitesi Fen Bilimleri Enstitüsü, Ankara, 2010.
- Elmas, Ç., Yapay Sinir Ağları, Seçkin Yayıncılık, Ankara, 2003.
- Elton, E.J., Gruber, M.J., Estimating The Dependence Structure Of Share Prices- Implications For Portfolio Selection, The Journal of Finance, 27: 1203-1233, 1973.
- Erdođan, E., Özyürek, H., Yapay Sinir Ağlarıyla Fiyat Tahminlemesi, Sosyal ve Beşerî Bilimler Dergisi, 4(1), 1309-8012, 2012.
- Erişlik, K., Girişim Şirketlerinin Finansal Başarısızlıklarının Yapay Sinir Ağları ve Lojistik Regresyon Analizi ile Tahmin Edilmesi, Yüksek Lisans Tezi, T.C. İstanbul Ticaret Üniversitesi Fen Bilimler Enstitüsü, İstanbul, 2020.
- Erođlu, G., Portföy Analizinde Bulanık Programlama, Yüksek Lisans Tezi, Ankara Üniversitesi Fen Bilimleri Enstitüsü, Ankara, 2006.
- Ertuna, İ.Ö., Yatırım ve Portföy Analizi, Bođaziçi Üniversitesi Yayınları, İstanbul, 5-30, 1983.
- Evans, J., Archer S.H., Diversification and Reduction of Dispersion, An Emprical Analysis, Journal of Finance, Vol.: 23, No: 5, 1968.

- Farrell, J. L., Portfolio Management: Theory and Application, The McGraw-Hill Companies Inc., Singapore, 1997.
- Fausett, L., Fundamentals of Neural Networks: Architectures, Algorithms and Applications. Englewood Cliffs, NJ: Prentice-Hall International, 1994.
- Fernandez, A., Gomez, S., Portfolio Selection Using Neural Networks, Computers & Operations Research, 34(4): 1177-1191, 2007.
- Fırat, M., Güngör, M., Askı Madde Konsantrasyonu ve Miktarının Yapay Sinir Ağları ile Belirlenmesi, Pamukkale Üniversitesi İMO Teknik Dergi, 3267-3282, 2004.
- Fisher, E., Donald – Jordan, J., Security Analysis and Portfolio Management, Second Edition, New Jersey, 1979.
- Flores, J.A., Focus on Artificial Neural Networks, Nova Science Publishers, 2011.
- Francis J.C., Archer, S.H., Portfolio Analysis, Prentice- Hall, New Jersey, 1971.
- Freitas, F.D., vd., Prediction-Based Portfolio Optimization Model Using Neural Networks, Neurocomputing, 72(10): 2155-2170, 2009.
- Fyfe, C., Artificial Neural Networks and Information Theory, The University of Paisley, 2000.
- Galton, F., Regresyon Towards Mediocrity in Hereditary Stature, Journal of Anthropological Institute of Great Britain and Ireland, 15, 1886.
- Gately, E., Neural Networks for Financial Forecasting, JohnWiley&Sons Inc., New York, 1996.
- Gömlüksiz, M., Alagöz, M., İktisadi Büyüme Olgusuna Ekonometrik Bir Yaklaşım: "BRIMCH" Ülkeleri ve Türkiye Örneği, SÜ İİBF Sosyal ve Ekonomik Araştırmalar Dergisi, Sayı: 24, 2012.
- Gujirati, Damodar N., Temel Ekonometri Ders Kitapları, Literatür, (Çev:Şenesen, Ü., Şenesen, Gülay G.), İstanbul, 2018.
- Gurney, K., Computers and Symbols Versus Nets and Neurons, UCL Draft Papers, No:1, U.K, 1996.

- Gülseçen, S., Yapay Sinir Ağları, İşletme Alanında Uygulanması ve Bir Örnek Çalışma, Basılmamış Doktora Tezi, İstanbul Üniversitesi Sosyal Bilimler Enstitüsü, İstanbul, 1993.
- Günay, S., Eğrioğlu, E., Aladağ, Ç.H., Yapay Sinir Ağları ile Türkiye Elektrik Tüketiminin Tahmini, TUIK 16. İstatistik Araştırma Sempozyumu Bildiriler Kitabı, Ankara, 2007.
- Gür, N., Hisse Senedi Fiyat Hareketlerinin Tahmini için Bir Yapay Sinir Ağı Modeli Önerisi, Yüksek Lisans Tezi, Kocaeli Üniversitesi Fen Bilimleri Enstitüsü, Kocaeli, 2009.
- Hamzaçebi, C., Yapay Sinir Ağları: Tahmin Amaçlı Kullanımı, Matlab ve Neurosolutions Uygulamalı, Ekin Yayınevi, Bursa, 2011.
- Haugen, R.A., Modern Investment Theory, Prentice Hall, USA, 201-2272, 2001.
- Haykin, S., Neural Networks and Learning Machines, Pearson Prentice Hall, 2008.
- Haykin, S., Neural Networks: A Comprehensive Foundation, Prentice Hall International, Inc., 1999.
- Hecht-Nielsen, R., Neurocomputing, Addison-Wesley, Reading, MA., 1990.
- Hill, T., Marquez, L., O'Connor, M., & Remus, W., Artificial Neural Network Models for Forecasting And Decision Making, International Journal of Forecasting, 10(1), 5-15, 1994.
- Horne, James C. Van, Finansal Yönetim ve Politikaları, (Çeviri: Tekok, O., Yener, D., Bekçioğlu, S.), Ankara, 1978.
- <https://piyasarehberi.org/yatirim/temel-analiz/190-piyasa-degeri-defter-degeri-pd-dd-orani-nedir-nasil-hesaplanir> (Erişim Tarihi: 20 Şubat 2021).
- İlhan, Z., Durağan Portföy Analizi ve Borsa İstanbul Verilerine Uygulanması, Yüksek Lisans Tezi, Hacettepe Üniversitesi Fen Bilimleri Enstitüsü, Ankara, 2016.
- İnam, M., Türkiye’de Menkul Kıymet Piyasası ve Yatırım Alternatiflerinin Genel Analizi, Gayret Matbaası, Ankara, 1987.
- Jain, A.K., Mao, J., Artificial Neural Networks: A Tutorial, IEEE, 1996.

- Kara, Y., vd., Predicting Direction of Stock Price Index Movement Using Artificial Neural Networks and Support Vector Machines: The Sample of The Istanbul Stock Exchange, *Expert Systems with Applications*, 38(5), 5311-5319, 2011.
- Karaatlı, M., Güngör, İ., Demir, Y. ve Kalaycı, Ş., Hisse Senedi Fiyat Hareketlerinin Yapay Sinir Ağları Yöntemi ile Tahmin Edilmesi, *Yönetim ve Ekonomi Araştırmaları Dergisi*, 3(3), 38-48, 2005.
- Karan, M.B., Yatırım Analizi ve Portföy Yönetimi, Hüfam Yayınları, Ankara, 2001.
- Karaşin, G., Sermaye Piyasası Analizleri, Sermaye Piyasası Yayın No: 4, Ankara, 1986.
- Kardiyen, F., Dinamik Portföy Analizi: Yeni Bir Model Önerisi, Doktora Tezi, Gazi Üniversitesi Fen Bilimleri Enstitüsü, Ankara, 2007.
- Kasabov, N.K., Foundations of Neural Networks, Fuzzy Systems and Knowledge Engineering, The MIT Press, 1996.
- Kaya, C., Doğrusal Olmayan Programlama ile Portföy Analizi, Yüksek Lisans Tezi, Mimar Sinan Güzel Sanatlar Üniversitesi Fen Bilimleri Enstitüsü, İstanbul, 2012.
- Kiang, M. Y., Extending the Kohonen Self-Organizing Map Networks for Clustering Analysis, *Computational Statistics & Data Analysis*, 38, 2001.
- Kohonen, T., Self-Organisation and Associative Memory, Springer-Verlag, 1989.
- Konno, H., Yamazaki, H., Mean-Absolute Deviation Portfolio Optimization Model and Its Applications to Tokyo Stock Market, *Management Science*, 37: 519- 531, 1991.
- Koutsoyiannis, A., Ekonometri Kuramı: Ekonometri Yöntemlerinin Tanıtımına Giriş ve Teori, Ankara, 1989.
- Köse, E., Doğrusal Olmayan Programlama Yöntemlerinden Kuadratik Programlama ile İMKB 30'da Portföy Oluşturma Uygulaması, Yüksek Lisans Tezi, Marmara Üniversitesi Sosyal Bilimler Enstitüsü, İstanbul, 2001.

- Kröse, B., Van der Smagt P., An Introduction to Neural Networks, The University of Amsterdam, 1996.
- Kutlu, B., Badur, B., Yapay Sinir Ağları ile Borsa Endeksi Tahmini, Boğaziçi Üniversitesi Yönetim Dergisi, 20(63), 25- 40, 2009.
- MacKay, David J. C., Information Theory, Inference and Learning Algorithms, Cambridge University Press, 43, 2003.
- Mandic, D.P., Chambers, J. A., Recurrent Neural Networks for Prediction- Learning Algorithms Architectures and Stability, John Wiley & Sons Ltd, 2001.
- Mansini, R., Ogryczak, W., Speranza, M.G., Linear and Mixed Integer Programming for Portfolio Optimization, Springer, 21, 2015.
- Markowitz, H., Portfolio Selection, Journal of Finance, Sayı 7, No:1, 1952.
- Mehrotra, K., Mohan, C.K., Ranka, S., Elements of Artificial Neural Networks, MIT Press, 1997.
- Minsky, M., Papert, S., Perceptrons, The MIT Press, 1969.
- Nygren, K., Stock Prediction: A Neural Network Approach, Master Thesis, Royal Institute of Technology, KTH, 2004.
- Oberuc, R.E., Dynamic Portfolio Theory and Management: Using Active Asset Allocation to Improve Profits and Reduce Risk, McGraw-Hill, USA, 28-47, 2003.
- Oğuzlar, A., Veri Madenciliğine Giriş Ekin Kitabevi, Bursa, 2004.
- Okutan, C., Borsa İstanbul Şirketlerinin Hisse Senedi Getirilerinin Yapay Sinir Ağları ve Çoklu Regresyon Yöntemleri Kullanarak Analizi, Yüksek Lisans Tezi, Kocaeli Üniversitesi Fen Bilimleri Enstitüsü, Kocaeli, 2014.
- Orhunbilge N., Uygulamalı Regresyon ve Korelasyon Analizi, İstanbul Üniversitesi, Basım ve Yayınevi Müdürlüğü, İstanbul, 2010.
- Öner, E., İşletme Yönetiminde Sistem Yaklaşımı, 3.Basım, Alfa A.Ş, İstanbul, 1998.

- Özçam, F., Teknik Analiz ve İstanbul Menkul Kıymetler Borsası, 1. Basım, SPK Yayınları, Ankara, 1996.
- Özçam, M., Varlık Fiyatlama Modelleri Aracılığıyla Dinamik Portföy Yönetimi, Tisamat Basım Sanayi, 221, Ankara, 1997.
- Öztemel E., Yapay Sinir Ağları, Papatya Yayıncılık, İstanbul, 2003.
- Öztemel, E., Yapay Sinir Ağları, 1. baskı, Papatya Yayıncılık, İstanbul, 2006.
- Öztemel, E., Yapay Sinir Ağları, Papatya Yayıncılık, İstanbul, 2012.
- Polat, E., Türkiye’de Düzey-2 Bölgeleri Kamu Yatırımları Etkinliğinin Veri Zarflama Analizi ile Ölçülmesi, Yayınlanmamış Doktora Tezi, İnönü Üniversitesi Sosyal Bilimler Enstitüsü, Malatya, 2014.
- Rumelhart, D. E., McClelland, J. L., Parallel Distributed Processing: Explorations in the Microstructure of Cognition, MIT Press, 1986.
- Sağıroğlu, S., Beşdök, E., Erler, M., Mühendislikte Yapay Zekâ Uygulamaları-1: Yapay Sinir Ağları, Ufuk Yayıncılık, 2003.
- Saraç, T., Yapay Sinir Ağları, Seminer Projesi, Gazi Üniversitesi Endüstri Mühendisliği Anabilim Dalı, Ankara, 2004.
- Serper Ö., Uygulamalı İstatistik 2, Filiz Kitapevi, İstanbul, 1996.
- Sevinç, E., İMKB-30 Endeksinde Yer Alan Menkul Kıymetlerden Ortalama-Varyans Modeline Göre Optimal Portföy Oluşturulması ve Riske Maruz Değer Yaklaşımıyla Portföy Riskinin Hesaplanması, Yüksek Lisans Tezi, İstanbul Üniversitesi Sosyal Bilimler Enstitüsü, İstanbul, 2007.
- Sharpe, W. F., Portföy Teorisi ve Sermaye Piyasaları, (Çev: Bekçioğlu, S.), Ankara, 1988.
- Smith, K.A., Neural Networks for Business: An Introduction, Neural Networks in Business: Techniques and Applications, Idea Group Publishing, USA, 2002.
- Şen, Z., Yapay Sinir Ağları İlkeleri, Su Vakfı Yayınları, İstanbul, 2004.

- Şişçi, M., Yapay Sinir Ağları İle Hisse Senedi Kapanış Fiyatlarının Tahmini ve Portföy Optimizasyonu, Yüksek Lisans Tezi, Dumlupınar Üniversitesi Fen Bilimleri Enstitüsü, Kütahya, 2017.
- Tatoğlu, F. Y., Panel Veri Ekonometrisi, Beta Yayınları, İstanbul, 2014.
- Tatoğlu, F.Y., Panel Veri Ekonometrisi, 1. Baskı, Beta Basım Yayım Dağıtım, İstanbul 2012
- Tektaş, A., Karataş, A., Yapay Sinir Ağları ve Finans Alanına Uygulanması: Hisse Senedi Fiyat Tahminlemesi, Atatürk Üniversitesi İktisadi ve İdari Bilimler Dergisi, 18(3-4), 2004.
- Ticknor J.L., A Bayesian Regularized Artificial Neural Network for Stock Market Forecasting. Expert Systems with Applications, 40(14): 5501-5506, 2013.
- Tokuçcu, H., Robust Optimizasyon Yaklaşımı ile Çok Dönemli Portföy Yönetimi ve Türkiye Uygulaması, Yüksek Lisans Tez Önerisi, Hacettepe Üniversitesi Sosyal Bilimler Enstitüsü, Ankara, 2005.
- U.S. Defense Advanced Research Projects Agency (DARPA), DARPA Neural Network Study, Lincoln Laboratory Technical Report, ESD-TR- 88-311, Massachusetts Institute of Technology, Lexington, Massachusetts, 1989.
- Uçak, S., Sürdürülebilir Kalkınma Bağlamında Alternatif Enerji ve Enerji Üretimi-Büyüme İlişkisi: Panel Veri Analizi, Yayınlanmamış Doktora Tezi, Kocaeli Üniversitesi Sosyal Bilimler Enstitüsü, Kocaeli, 2010.
- Ulusoy, T., İMKB Endeks Öngörüsü için İleri Beslemeli Ağ Mimarisine Sahip Yapay Sinir Ağı Modellemesi, Uluslararası İktisadi ve İdari İncelemeler Dergisi, 3(5), 21-40, 2010.
- Uslu, Ç. S., Zaman Serisi Analizi İle Yapay Sinir Ağları Kestirimlerinin Karşılaştırılması, Yüksek Lisans Tezi, Mimar Sinan Güzel Sanatlar Üniversitesi Fen Bilimleri Enstitüsü, İstanbul, 2011.
- Usta, Ö., İşletme Finansı ve Finansal Yönetim, Detay Yayıncılık, Ankara, 2008.

- Üstünel, İ.E., Durağan Portföy Analizi ve İMKB Verilerine Uygulanması, Emir Ofset, Ankara, 2000.
- Vaisla, K. S., Bhatt, A. K., An Analysis of The Performance of Artificial Neural Network Technique For Stock Market Forecasting, International Journal On Computer Science And Engineering, 2(6), 2104-2109, 2010.
- Vural, B. B., Yapay Sinir Ağları ile Finansal Tahmin, Yüksek Lisans Tezi, Ankara Üniversitesi Sosyal Bilimler Enstitüsü, Ankara, 2007.
- Yadav, N., Yadav, A., Kumar, M., An Introduction to Neural Network Methods for Differential Equations, Springer, 2015.
- Yalçın, E., Portföy Yönetimi Teorileri ve İMKB’de Uygulaması, Yayınlanmamış Yüksek Lisans Tezi, Dokuz Eylül Üniversitesi Sosyal Bilimler Enstitüsü İzmir, 2006.
- Yao J., Li, Y., vd., Option Price Forecasting Using Neural Networks, The International Journal Of Management Science, 28(4): 455-466, 2000.
- Yavuz, M., Sakarya, Ş., Özdemir, N., Yapay Sinir Ağları ile Risk-Getiri Tahmini ve Portföy Analizi, İktisadi Ve İdari Bilimler Fakültesi Dergisi, 8(4), 2015.
- Yavuz, M., Yapay Sinir Ağları ile Portföy Optimizasyonu, Yüksek Lisans Tezi, Balıkesir Üniversitesi Fen Bilimleri Enstitüsü, Balıkesir, 2012.
- Yıldırım, S., Kurumsal İktisat Bağlamında Ülkeler Arası Büyüme Farklılıklarının Panel Veri Analizi, Yayınlanmamış Doktora Tezi, Anadolu Üniversitesi Sosyal Bilimler Enstitüsü, Eskişehir, ABD, 2009.
- Yıldız, B. Finansal Başarısızlığın Öngörülmesinde Yapay Sinir Ağı Kullanımı ve Ampirik Bir Çalışma, Yayınlanmamış Doktora Tezi, Dumlupınar Üniversitesi Sosyal Bilimler Enstitüsü, Kütahya, 1999.
- Yiğiter, Ş. Y., Sarı, S. S., Başakın, E. E., Hisse Senedi Kapanış Fiyatlarının Yapay Sinir Ağları ve Bulanık Mantık Çıkarım Sistemleri ile Tahmin Edilmesi, Sütçü İmam Üniversitesi İbf Dergisi, 7(1), 1-22, 2017.

- Yurtođlu, H., Yapay Sinir Ađları Metodolojisi ile Öngörü Modellemesi: Bazı Makroekonomik Deđişkenler için Türkiye Örneđi, Uzmanlık Tezi, Ekonomik Modeller ve Stratejik Arařtırmalar Genel Müdürlüğü, Ankara, 2005.
- Zhang, P. G., Business Forecasting with Artificial Neural Networks: An Overview, Neural Networks in Business Forecasting, Idea Group Publishing, 78, 2003.
- Zhang, Y. ve Wu, L., Stock Market Prediction Of S&P 500 Via Combination Of İmproved BCO Approach and BP Neural Network, Expert Systems with Applications, 36(5), 8849-8854, 2009.

ÖZGEÇMİŞ

Adı Soyadı : Nur Miray Aytekin
Doğum yeri : Ankara
Doğum tarihi : 17.10.1992
Medeni hali : Bekar
Yazışma adresi : Hipodrum cad. no:13 Türk Patent ve Marka Kurumu
Ankara
Telefon : 05352750470
Elektronik posta adresi : nurmirayaytekin@hotmail.com
Yabancı dili : İngilizce

EĞİTİM DURUMU

Lisans : Ankara Üniversitesi, İstatistik Bölümü
Yüksek Lisans : Hacettepe Üniversitesi, İstatistik Bölümü

İş Tecrübesi

2017- 2018 : Bilkent Holding, Tepe Güvenlik A.Ş, İnsan Kaynakları Uzman Yardımcısı
2018- Devam Ediyor : Türk Patent ve Marka Kurumu, Sözleşmeli Personel

ARKALI ÖNLÜ BASKI İÇİN BOŞ BIRAKILMIŞTIR.

TEZ BASIMINDA BU YAZIYI SİLİNİZ!...

