

T.C.
GAZİANTEP ÜNİVERSİTESİ
SOSYAL BİLİMLER ENSTİTÜSÜ
İŞLETME ANA BİLİM DALI

**YAPAY ZEKÂ YÖNTEMLERİ İLE İŞLETMELERİN
FİNANSAL BAŞARISIZLIĞININ TAHMİN EDİLMESİ:
BİST İMALAT SANAYİ UYGULAMASI**

DOKTORA TEZİ

MUHAMMED FATİH YÜRÜK

GAZİANTEP
HAZİRAN 2019

T.C.
GAZIANTEP ÜNİVERSİTESİ
SOSYAL BİLİMLER ENSTİTÜSÜ
İŞLETME ANA BİLİM DALI

**YAPAY ZEKÂ YÖNTEMLERİ İLE İŞLETMELERİN
FİNANSAL BAŞARISIZLIĞININ TAHMİN EDİLMESİ:
BİST İMALAT SANAYİ UYGULAMASI**

DOKTORA TEZİ

MUHAMMED FATİH YÜRÜK

Tez Danışmanı: Doç. Dr. İbrahim Halil EKŞİ

GAZIANTEP
HAZİRAN 2019

T.C.
GAZİANTEP ÜNİVERSİTESİ
SOSYAL BİLİMLER ENSTİTÜSÜ
İŞLETME ANA BİLİM DALI

Yapay Zekâ Yöntemleri İle İşletmelerin Finansal Başarısızlığının Tahmin Edilmesi: BİST İmalat Sektörü Uygulaması

Muhammed Fatih YÜRÜK

Tez Savunma Tarihi: 19.06.2019

Sosyal Bilimler Enstitüsü Onayı


Doç.Dr. Zekiye ANTAKYALIOĞLU
SBE Müdürü

Bu tezin Doktora tezi olarak gerekli şartları sağladığımı onaylarım.


Prof.Dr.H.Mustafa PAKBOY
Enstitü ABD Başkanı

Bu tez tarafımda okunmuş, kapsamı ve niteliği açısından bir Doktora tezi olarak kabul edilmiştir.


Doç.Dr.İbrahim Halil EKŞİ
Tez Danışmanı

Bu tez tarafımızca okunmuş, kapsam ve niteliği açısından bir Yüksek Lisans/Doktora tezi olarak oybirliği ile kabul edilmiştir.

Jüri Üyeleri:
(Unvanı, Adı ve SOYADI)

Prof.Dr.İbrahim Halil SEYREK

Prof.Dr.Erhan DEMİRELİ

Doç.Dr.İbrahim Halil EKŞİ

Doç.Dr.Tuba BAŞKONUŞ DİREKÇİ

Dr.Öğrt.Üyesi Şükriye Gül REİS

İmzası



ETİK BEYAN

Gaziantep Üniversitesi Sosyal Bilimleri Enstitüsü Tez Yazım Kurallarına uygun olarak hazırladığım bu tez çalışmada;

- Tez içinde sunduğum verileri, bilgileri ve dokümanları akademik ve etik kurallar çerçevesinde elde ettiğimi,
- Tüm bilgi, belge, değerlendirme ve sonuçları bilimsel etik ve ahlak kurallarına uygun olarak sunduğumu,
- Tez çalışmada yararlandığım eserlerin tümüne uygun atıfta bulunarak kaynak gösterdiğimi,
- Kullanılan verilerde herhangi bir değişiklik yapmadığımı,
- Bu tezde sunduğum çalışmanın özgün olduğunu bildirir, aksi bir durumda aleyhime doğabilecek tüm hak kayıplarını kabullendiğimi beyan ederim.

Muhammed Fatih YÜRÜK



*Annem, Babam,
Eşim Reyyan,
Kızım Zeynep Serra ve Oğlum Hasan Erdem'e*

ÖZET

YAPAY ZEKÂ YÖNTEMLERİ İLE İŞLETMELERİN FİNANSAL BAŞARISIZLIĞININ TAHMİN EDİLMESİ: BİST İMALAT SEKTÖRÜ UYGULAMASI

YÜRÜK, Muhammed Fatih
Doktora Tezi, İşletme ABD
Tez Danışmanı: Doç. Dr. İbrahim Halil EKŞİ
Haziran 2019, 178 sayfa

Finansal başarısızlık, işletmelerin geleceğini tehdit etmesi yanı sıra başarısız işletme sayısının artmasıyla ülkenin ekonomik büyümesi üzerinde olumsuz etki yaratmaktadır. Başarısızlığı önceden öngörmek ve bunun neticesinde tedbirler alıp sıkıntılı durumdan kurtulmak, işletmeler açısından hayati derecede önemlidir. Finansal başarısızlığın önceden tahmini konusunda birçok modeller geliştirilmiştir. Bu modeller daha çok istatistiki teknikler ve yapay zekâ teknikleridir. Bu çalışmada finansal başarısızlık tahminleri yapay sinir ağları, destek vektör makineleri ve ensemble öğrenme modelleri kullanılarak yapılmıştır. BİST imalat sektöründe işlem gören/görmüş olan 140 şirket örneklem olarak alınmıştır. Modele girdi değişkenleri olarak literatürde sık kullanılan 26 finansal oran kullanılmıştır. Çalışmada modellerin sınıflandırma performansları karşılaştırılmış, yapılan sınıflandırmanın doğruluk, özgüllük ve duyarlılık yüzdeleri hesaplanmıştır. Ayrıca çalışmanın değişkenlerini teşkil eden 26 finansal oranın modeldeki önem değerleri hesaplanmıştır. Tahmin modellerinin performansları sınıflandırma problemlerinde kullanılan ROC eğrileri ile ölçülmüştür. Çalışma sonucunda yapay sinir ağları, destek vektör makinelerine göre daha iyi sınıflandırma performansı gösterirken, ensemble diğer iki makine öğrenmesi modeline göre daha iyi bir sınıflandırma yapmıştır.

Anahtar kelimeler: Destek Vektör Makineleri, Yapay Sinir Ağları, Ensemble, Yapay Zekâ, Finansal Başarısızlık, ROC

ABSTRACT

FINANCIAL FAILURE PREDICTION OF COMPANIES USING ARTIFICIAL INTELLIGENCE METHODS: AN APPLICATION IN BIST MANUFACTURING SECTOR

YÜRÜK, Muhammed Fatih

Ph.D. Thesis, Department of Business Administration

Supervisor: Doç. Dr. İbrahim Halil EKŞİ

June 2019, 178 pages

The financial failure affects negatively on a country's economical growth with the increase in the number of businesses as it threatens their future. It is significantly important to foresee the failure so to take precautions as its result and get out of the problems for the businesses. Many models were developed about the estimation of financial failure. These models are mostly statistical and artificial intelligence techniques. The estimations of financial failure were made with the use of artificial neural networks, support vector machines and ensemble learning models in this study. 140 companies which are dealt/ were dealt in the manufacturing sector in Istanbul Stock Exchange were received as the sample. 26 financial rates which are frequently used in the literature were used as the model's input variables. The model's classification performances were compared in the study, and the accuracy, specificity and sensitivity percentages were calculated for that classification. Moreover, the significance values of model related to 26 financial rates which constitute the study's variables were calculated. The performances of estimation models were measured with ROC curves which were used in the classification problems. As a result of the study, while the artificial neural networks had a better classification performance than the support vector machines and the ensemble had a better classification than the other two machine learning models.

Key words: Support Vector Machines, Artificial Neural Networks, Artificial Intelligence, Ensemble, Financial Failure, ROC

ÖNSÖZ

Tez çalışmasının ilk aşamasından itibaren her türlü desteği verip, bu alanda çalışmam konusunda beni cesaretlendiren değerli hocam ve danışmanım Sayın Doç. Dr. İbrahim Halil EKŞİ'ye, tez izleme komitesinde bulunan ve bana tez süresince bilgi ve birikimlerini aktaran, saygıdeğer hocalarım, Sayın Doç. Dr. Tuba BAŞKONUŞ DİREKÇİ ve Sayın Dr. Öğr. Üyesi Şükriye Gül REİS'e, tez savunma sınavıma jüri üyesi olarak katılarak değerli fikirlerini sunan Sayın Prof. Dr. İbrahim Halil SEYREK ve Sayın Prof. Dr. Erhan DEMİREL'e çok teşekkür eder, şükranlarımı sunarım.

Doktoraya başladığım bilimsel hazırlık sürecinden tez aşamasına kadar geçen bu uzun süre zarfında beni motive eden, destek veren, her türlü fedakârlığı gösteren kıymetli ve vefakâr eşim Reyyan'a, ayrıca ders ve tez aşamasında benim moral ve enerji kaynaklarım kızım Zeynep Serra ve oğlum Hasan Erdem'e, dualarını ve desteklerini esirgemeyen aileme çok teşekkür ederim.

Son olarak isimlerini yazamadığım, tez çalışması sırasında desteklerini esirgemeyen herkese teşekkür ederim.

Haziran 2019
Muhammed Fatih YÜRÜK

İÇİNDEKİLER

ÖNSÖZ.....	iii
İÇİNDEKİLER	iv
TABLolar LİSTESİ.....	viii
ŞEKİLLER LİSTESİ.....	x
KISALTMALAR	xiii
BİRİNCİ BÖLÜM	1
FİNANSAL BAŞARISIZLIK	1
1.1. GİRİŞ.....	1
1.2. FİNANSAL BAŞARISIZLIK KAVRAMI.....	3
1.3. FİNANSAL BAŞARISIZLIĞIN NEDENLERİ	8
1.3.1 İşletme içi nedenler	10
1.3.2. İşletme dışı nedenler	13
1.3.2.1. Toplumsal çevre	13
1.3.2.2. Yasal ve politik çevre.....	14
1.3.2.3. Ekonomik çevre	14
1.3.2.4. Doğal çevre	14
1.3.2.5. Teknolojik çevre.....	15
1.4. FİNANSAL KRİZ VE FİRMA BAŞARISIZLIĞI	16
1.4.1. Finansal kriz.....	16
1.4.2. Finansal kriz türleri.....	17
1.4.3. Krizler ve işletme başarısızlığı	18
1.4.4. Kriz dönemlerinde maliyetlerin mali başarısızlığa etkisi	20
1.5. FİNANSAL BAŞARISIZLIK İÇİN ALINABİLECEK ÖNLEMLER.....	21
1.5.1. Yeniden yapılanma (Reorganization)	22
1.5.1.1. Borçların vadesinin uzatımı	24
1.5.1.2. Alacaklıların alacaklarının bir kısmından vazgeçmesi	25
1.5.1.3. İşletmenin alacaklıların temsilcilerinden oluşan bir komite tarafından yönetilmesi	26
1.5.1.4. Konkordato önerilmesi.....	27
1.5.2. Sermaye yapısının yeniden düzenlenmesi	28
1.5.3. İşletmenin tasfiyesi	29
1.6. FİNANSAL BAŞARISIZLIK TAHMİNİ.....	30
1.6.1. Finansal başarısızlığın tahmin edilmesinin önemi.....	30
1.6.1.1. İşletme yöneticileri açısından önemi.....	31

1.6.1.2. Yatırımcılar açısından önemi	31
1.6.1.3. Devlet açısından önemi	32
1.6.1.4. İş ve işçi kuruluşları açısından önemi	33
1.6.1.5. Bağımsız denetçiler açısından önemi	34
1.6.1.6. Düzenleyici kuruluşlar açısından önemi	35
1.6.1.7. Kredi kurumları açısından önemi	35

İKİNCİ BÖLÜM

FİNANSAL BAŞARISIZLIK TAHMİNİNDE KULLANILAN MODELLER. 37

2.1. MATEMATİKSEL VE İSTATİSTİKSEL MODELLER.....	37
2.1.1. Tek değişkenli istatistiksel modeller.....	38
2.1.2. Çok değişkenli istatistiksel modeller	39
2.1.2.1. Çok değişkenli modellerde kullanılan istatistiksel teknikler	40
2.1.2.1.1. Diskriminant analizi	41
2.1.2.1.2. Çok değişkenli regresyon analizi	44
2.1.2.1.3. Logit model	46
2.1.2.1.4. Probit model	48
2.2. YAPAY ZEKÂ VE MAKİNE ÖĞRENMESİ MODELLERİ.....	49
2.2.1. Uzman sistemler (US).....	53
2.2.2. Bulanık mantık.....	56
2.2.3. Genetik algoritmalar (GA).....	62
2.2.3.1. Genetik algoritmaların çalışma prensibi	63
2.2.3.2. Genetik algoritmaların güçlü ve zayıf yönleri	68
2.2.3.2.1 Güçlü yönleri	68
2.2.3.2.2. Zayıf Yönleri	69
2.2.4. Yapay sinir ağları (YSA)	69
2.2.4.1. Yapay sinir ağı tanımları	69
2.2.4.2. Biyolojik sinir ağları	71
2.2.4.3. Yapay sinir hücreleri	74
2.2.4.4. Yapay sinir ağının yapısı.....	77
2.2.4.5. Yapay sinir ağlarında öğrenme	78
2.2.4.5.1 Danışmalı öğrenme.....	79
2.2.4.5.2 Danışmansız öğrenme	80
2.2.4.6. Yapay sinir ağı mimarileri	81
2.2.4.6.1. İleri beslemeli ağlar	82
2.2.4.6.2. Geri beslemeli yapay sinir ağları.....	83
2.2.4.7. Yapay sinir ağlarının uygulama alanları	85
2.2.4.7.1 Finans, borsa ve kredi kartı alanında YSA kullanımı	86
2.2.4.7.2. Endüstriyel alanda YSA kullanımı.....	87
2.2.4.7.3. Tıp, uzay, otomotiv ve haberleşme alanında YSA kullanımı.....	88
2.2.4.8. Yapay sinir ağlarının güçlü yönleri.....	88
2.2.4.9. Yapay sinir ağlarının zayıf yönleri.....	89
2.2.5. Destek vektör makineleri	91
2.2.5.1. Doğrusal olarak ayrılabilen DVM.....	94
2.2.5.2. Doğrusal olarak ayrılamayan DVM.....	97
2.2.5.3. Kernel (çekirdek) fonksiyonları	100
2.2.6. Ensemble (Topluluk) öğrenme modeli	104
2.2.6.1. Bagging algoritması (Bootstrapping Aggregation).....	106

2.2.6.2 AdaBoost (Boosting).....	108
ÜÇÜNCÜ BÖLÜM	111
LİTERATÜR ARAŞTIRMASI	111
3.1. FİNANSAL BAŞARISIZLIK İLE İLGİLİ YURT DIŞI LİTERATÜR	111
3.2. FİNANSAL BAŞARISIZLIK İLE İLGİLİ YURT İÇİ LİTERATÜR	116
DÖRDÜNCÜ BÖLÜM	120
YAPAY ZEKÂ YÖNTEMLERİ İLE İŞLETMELERİN FİNANSAL BAŞARISIZLIĞININ TAHMİN EDİLMESİ: BİST İMALAT SEKTÖRÜ UYGULAMASI	120
4.1. MATERYAL VE YÖNTEM	120
4.2. KULLANILAN DEĞİŞKENLER	122
4.3. FİNANSAL BAŞARISIZ İŞLETMELERİN SINIFLANDIRILMA ÖLÇÜTLERİ.....	123
4.4. ÖRNEKLEM.....	124
4.5. UYGULAMA-BULGULAR.....	125
4.5.1. Yapay Sinir Ağları ile oluşturulan modelin değerlendirilmesi.....	125
4.5.1.1. Başarısızlıktan bir yıl önce (t-1) dönemi için YSA analiz sonuçları	125
4.5.1.2. Başarısızlıktan iki yıl önce (t-2) dönemi için YSA analiz sonuçları	127
4.5.1.3. Başarısızlıktan üç yıl önce (t-3) Dönemi İçin YSA Analiz Sonuçları	129
4.5.2. Destek vektör makineleri ile oluşturulan modelin değerlendirilmesi.....	131
4.5.2.1. Başarısızlıktan bir yıl önce (t-1) dönemi için DVM analiz sonuçları	132
4.5.2.2. Başarısızlıktan iki yıl önce (t-2) Dönemi İçin DVM Analiz Sonuçları	134
4.5.2.3. Başarısızlıktan üç yıl önce (t-3) Dönemi İçin DVM Analiz Sonuçları	136
4.5.3. Ensemble (Topluluk) öğrenme tekniği ile oluşturulan modelin değerlendirilmesi	137
4.5.3.1. Başarısızlıktan bir yıl önce (t-1) dönemi için ensemble öğrenme analiz sonuçları	138
4.5.3.2. Başarısızlıktan iki yıl önce (t-2) dönemi için ensemble öğrenme analiz sonuçları	139
4.5.3.3. Başarısızlıktan üç yıl önce (t-3) dönemi için ensemble öğrenme analiz sonuçları	141
4.5.4. Tüm dönemler için modellerin performanslarının toplu gösterimi	142
4.5.5. ROC (Receiver Operating Characteristic Curves) eğrileri ile oluşturulan modellerinin performanslarının değerlendirmesi.....	144
4.5.5.1. ROC eğrileri (Receiver Operating Characteristic Curves).....	144
4.5.5.2. YSA modelinin ROC eğrisi yardımıyla performanslarının değerlendirilmesi.....	147
4.5.5.2.1. (t-1) dönemi için ROC eğrisi altında kalan alanın değerlendirilmesi	147
4.5.5.2.2. (t-2) dönemi için ROC eğrisi altında kalan alanın değerlendirilmesi	148

4.5.5.2.3. (t-3) dönemi için ROC eğrisi altında kalan alanın değerlendirilmesi	149
4.5.5.3. DVM modelinin ROC eğrisi yardımıyla performanslarının değerlendirilmesi.....	149
4.5.5.3.1. (t-1) dönemi için ROC eğrisi altında kalan alanın değerlendirilmesi	149
4.5.5.3.2. (t-2) dönemi için ROC eğrisi altında kalan alanın değerlendirilmesi	150
4.5.5.3.3. (t-3) dönemi için ROC eğrisi altında kalan alanın değerlendirilmesi	151
4.5.5.4. Ensemble modelin ROC eğrisi yardımıyla performanslarının değerlendirilmesi.....	152
4.5.5.4.1. (t-1) dönemi için ROC eğrisi altında kalan alanın değerlendirilmesi	152
4.5.5.4.2. (t-2) dönemi için ROC eğrisi altında kalan alanın değerlendirilmesi	152
4.5.5.4.3. (t-3) dönemi için ROC eğrisi altında kalan alanın değerlendirilmesi	153
4.5.5.5. Tüm dönemler için oluşturulan modellerin performanslarının ROC eğrisi yardımıyla toplu olarak gösterimi	154
BEŞİNCİ BÖLÜM	158
SONUÇ VE ÖNERİLER	158
KAYNAKÇA	162
ÖZGEÇMİŞ	176
EKLER	177
EK A. Başarılı Firmalar Listesi	177
EK A. Başarılı Firmalar Listesi (Devamı).....	178
EK B. Başarısız Firmalar.....	179
EK B. Başarısız Firmalar (Devamı)	180

TABLOLAR LİSTESİ

							<u>Sayfa No</u>
Tablo 1.1. Literatürde Finansal Başarısızlık							5
Tablo 1.2. Mali Başarısızlığa Etki Eden Etmenler							10
Tablo 1.3. Başarısızlık Nedenleri ve Yüzdeleri							11
Tablo 2.1. Başarısızlık Konusunda Yapılan İstatistikî Modeller							36
Tablo 2.2. Çok Boyutlu Modellerde Kullanılan Oranlar							38
Tablo 2.3. Biyolojik Sınır Ağı ile YSA'nın Karşılaştırılması							72
Tablo 2.4. Toplama Fonksiyonları							74
Tablo 2.5. Aktivasyon Fonksiyonları							75
Tablo 2.6. YSA ve Uygulama Alanları							85
Tablo 2.7. En Sık Kullanılan Çekirdek Fonksiyonları							102
Tablo 2.8. Bagging ve Boosting Adımları							105
Tablo 4.1. Kullanılan Finansal Oranlar							121
Tablo 4.2. Yıllara Göre Başarısız İşletmelerin Sayısı							123
Tablo 4.3. (t-1) Dönemi İçin Oluşturulan YSA Modelinin Özellikleri ve Sınıflandırma Matrisi							125
Tablo 4.4. YSA Modeli İçin (t-1) Yılına Ait Önemli Değişkenler							125
Tablo 4.5. (t-2) Dönemi İçin Oluşturulan YSA Modelinin Özellikleri ve Sınıflandırma Matrisi							127
Tablo 4.6. YSA Modeli için (t-2) Yılına Ait Önemli Değişkenler							128
Tablo 4.7. (t-3) Dönemi İçin Oluşturulan YSA Modelinin Özellikleri ve Sınıflandırma Matrisi							129
Tablo 4.8. YSA Modeli için (t-2) Yılına Ait Önemli Değişkenler							130
Tablo 4.9. (t-1) Dönemi İçin Oluşturulan DVM Modelinin Özellikleri ve Sınıflandırma Matrisi							131
Tablo 4.10. DVM Modeli için (t-1) Yılına Ait Önemli Değişkenler							132
Tablo 4.11. (t-2) Dönemi İçin Oluşturulan DVM Modelinin Özellikleri ve Sınıflandırma Matrisi							133
Tablo 4.12. DVM Modeli için (t-2) Yılına Ait Önemli Değişkenler							134
Tablo 4.13. (t-3) Dönemi İçin Oluşturulan DVM Modelinin Özellikleri ve Sınıflandırma Matrisi							135

Tablo 4.14. DVM Modeli için (t-3) Yılına Ait Önemli Değişkenler.....	136
Tablo 4.15. (t-1) Dönemi İçin Oluşturulan Ensemble Modelinin Özellikleri ve Sınıflandırma Matrisi.....	137
Tablo 4.16. (t-2) Dönemi İçin Oluşturulan Ensemble Modelinin Özellikleri ve Sınıflandırma Matrisi.....	139
Tablo 4.17. (t-3) Dönemi İçin Oluşturulan Ensemble Modelinin Özellikleri ve Sınıflandırma Matrisi.....	140
Tablo 4.18. Sınıflandırma Matrisi.....	141
Tablo 4.19. Oluşturulan Modellerin Duyarlılık, Özgüllük, Doğruluk Oranlarını Toplu Gösterimi.....	143
Tablo 4.20. (t-1) Dönemi YSA Modeli İçin ROC Eğrisi Altında Kalan Alan.....	146
Tablo 4.21. (t-2) Dönemi YSA Modeli İçin ROC Eğrisi Altında Kalan Alan.....	147
Tablo 4.22. (t-3) Dönemi YSA Modeli İçin ROC Eğrisi Altında Kalan Alan.....	148
Tablo 4.23. (t-1) Dönemi DVM Modeli İçin ROC Eğrisi Altında Kalan Alan.....	148
Tablo 4.24. (t-2) Dönemi DVM Modeli İçin ROC Eğrisi Altında Kalan Alan.....	149
Tablo 4.25. (t-3) Dönemi DVM Modeli İçin ROC Eğrisi Altında Kalan Alan.....	150
Tablo 4.26. (t-1) Dönemi Ensemble Modeli İçin ROC Eğrisi Altında Kalan Alan.....	151
Tablo 4.27. (t-2) Dönemi Ensemble Modeli İçin ROC Eğrisi Altında Kalan Alan.....	151
Tablo 4.28. (t-3) Dönemi Ensemble Modeli İçin ROC Eğrisi Altında Kalan Alan.....	152
Tablo 4.29. Tüm Modellerin ROC Eğrisinin Altında Kalan Alanların Gösterimi.....	152

ŞEKİLLER LİSTESİ

	<u>Sayfa No</u>
Şekil 1.1. İşletmelerin Başarısızlığın Oluşum Süreci	7
Şekil 1.2. Finansal Krizlerin Sınıflandırılması	18
Şekil 2.1. İki Gruplu Diskriminant Analizinin Grafikselleştirilmesi.....	41
Şekil 2.2. Logit ve Probit birikimli dağılımlar.....	48
Şekil 2.3. Turing Testi.....	51
Şekil 2.4. Uzman Sistemlerin Yapısı.....	53
Şekil 2.5. Klasik Mantık.....	56
Şekil 2.6. Bulanık Mantık.....	57
Şekil 2.7. Üçgen Üyelik Fonksiyonu.....	58
Şekil 2.8. Yamuk Üyelik Fonksiyonu.....	58
Şekil 2.9. Gauss Üyelik Fonksiyonu ve Grafiği.....	59
Şekil 2.10. Bell Üyelik Fonksiyonu ve Grafiği.....	59
Şekil 2.11. Sigmoid Üyelik Fonksiyonu ve Grafiği.....	60
Şekil 2.12. a) Genetik Algoritma Pseudocode.....	62
Şekil 2.12. b) Genetik Algoritma Akış Diyagramı.....	63
Şekil 2.13. Mutasyon Yöntemleri.....	65
Şekil 2.14. Turnuva Yöntemi İle Seçim.....	67
Şekil 2.15. Bir Biyolojik Nöronun Yapısı.....	70
Şekil 2.16. Matematiksel Olarak Nöron Ağının Gösterimi.....	70
Şekil 2.17. Sinaps Görünümü.....	71
Şekil 2.18. Yapay Sinir Hücresinin Yapısı.....	73
Şekil 2.19. Yapay Sinir Ağı Modeli.....	76
Şekil 2.20. Danışmalı Öğrenme Yapısı.....	79
Şekil 2.21. Danışmansız Öğrenme Yapısı.....	80

Şekil	2.22.	Yapay	Sinir				Ağı
Mimarisi.....							80
Şekil	2.23.	İleri	Beslemeli	Yapay	Sinir		Ağı
Mimarisi.....							82
Şekil	2.24.	Geri	Beslemeli				Ağ
Yapısı.....							83
Şekil 2.25. Tekrarlayan sinir ağı yapısı (3 giriş / 2 çıkış).....							84
Şekil	2.26.		Hiper				düzlem
Sınıflandırması.....							92
Şekil	2.27.	Destek	Vektörleri	ve			Optimal
Hiperdüzlem.....							93
Şekil 2.28. Doğrusal sınıflandırma: İki boyutlu bir giriş alanında görüntülenen benzersiz bir ayırıcı hiper düzlemin tanımı.....							94
Şekil	2.29.						Lagrange
Çarpanları.....							95
Şekil 2.30. Veri Çakışması Yaşanmayan Doğrusal Olmayan Bir DVM.....							97
Şekil	2.31.	Doğrusal	olmayan				SV
sınıflandırması.....							99
Şekil 2.32. Yüksek Dereceli Çekirdek Fonksiyonu ile Öznitelik Uzayına Dönüşüm.....							101
Şekil 2.33. Bir Çekirdek Fonksiyonu Kullanarak Yüksek Boyutlu Bir Özellik Alanına Eşleme.....							101
Şekil 2.34. Ensemble model oluşturmak için eğitim aşaması ve test aşaması. (a) Eğitim aşaması; (b) Test aşaması.....							104
Şekil 2.35. Bagging metodolojisi.....							106
Şekil	2.36.	Bagging	algoritması				sözde
kodu.....							107
Şekil	4.1.	İdeal ve Kötü Performans Gösteren					ROC
Eğrileri.....							145
Şekil	4.2.	(t-1) Dönemi	YSA Modeli				İçin ROC
Eğrisi.....							146
Şekil	4.3.	(t-2) Dönemi	YSA Modeli				İçin ROC
Eğrisi.....							147
Şekil	4.4.	(t-3) Dönemi	YSA Modeli				İçin ROC
Eğrisi.....							147
Şekil	4.5.	(t-1) Dönemi	DVM Modeli				İçin ROC
Eğrisi.....							148
Şekil	4.6.	(t-2) Dönemi	DVM Modeli				İçin ROC
Eğrisi.....							149
Şekil	4.7.	(t-3) Dönemi	DVM Modeli				İçin ROC
Eğrisi.....							149
Şekil	4.8.	(t-1) Dönemi	Ensemble Modeli				İçin ROC
Eğrisi.....							150
Şekil	4.9.	(t-2) Dönemi	Ensemble Modeli				İçin ROC

Eğrisi.....	151						
Şekil 4.10. (t-3) Dönemi		Ensemble	Modeli	İçin	ROC		
Eğrisi.....	152						



KISALTMALAR**TTK:** Türk Ticaret Kanunu**US:** Uzman sistemler**GA:** Genetik Algoritma**YSA:** Yapay Sinir Ağları**DVM:** Destek Vektör Makineleri**MB:** Merkez Bankası**KGK:** Kamu Gözetimi Muhasebe ve Denetim Standartları Kurumu**TMSF:** Tasarruf Mevduatı Sigorta Fonu**BDDK:** Bankacılık Düzenleme ve Denetleme Kurumu**SPK:** Sermaye Piyasası Kurulu**YZ:** Yapay Zekâ

BİRİNCİ BÖLÜM

FİNANSAL BAŞARISIZLIK

1.1. GİRİŞ

Küreselleşen dünya ile birlikte gelişen bilişim teknolojileri sınır kavramını ortadan kaldırmış, devletleri birbirine yakınlaştırmıştır. Bu yakınlaşma ile birlikte eski dışa kapalı finansal yönetim anlayışları değişmiş ve rekabet daha fazla artmıştır. Bilişim ve ağ teknolojileri ile işletmeler, dünyanın başka bir yerinde bulunan işletmeler, sektörler ve mali piyasalar hakkındaki bilgiye saniyeler içinde ulaşabilmektedir. Rakip bir işletmenin durumu hakkında veri elde edilmesiyle işletmeler daha farklı pazarlama, üretim, yönetim ve finans stratejileri oluşturabilmektedir. Özetle bilgi tabanlı yenedünya düzeninde rekabet kızışmakta, sektörler çok hızlı bir şekilde değişime uğramaktadırlar. Bu değişime ayak uyduramayan ve bilişim teknolojilerine uzak olan işletmelerin rekabet güçlerini yitirmeleri ve sonrasında başarısızlık durumuna uğramaları muhtemel görünmektedir.

İşletmelerin başarısızlığa uğramasından doğan finansal kriz sadece ilgili işletmeyi ilgilendiren bir durum değil, yayılma etkisi ile tüm toplumu etkileyen bir olgudur. Başarısız işletme sayısının artması ile birlikte meydana gelen işsizlik oranındaki artış, devletlerin ekonomik düzenini ve refahını olumsuz etkileyebilmektedir. Bu sebeple başarısızlık durumunu mikro düzeyde değil makro düzeyde değerlendirmek daha doğru bir yaklaşımdır. Ülkeler için bu denli önemli bir durumun önceden teşhis edilip uygun tedavi yöntemlerinin hayata geçirilmesi, ekonomik yapının daha az zarara uğramasını sağlar.

İşletmelerdeki finansal başarısızlık kavramı, en net ifade ile mali yükümlülüklerin yerine getirilememesi olarak tanımlanmaktadır. Kısa ve uzun vadeli yükümlülüklerini yerine getirememesi, işletmeleri finansal başarısızlıkla karşı

karşıya getirebilir. Bu başarısızlığın içsel ve dışsal nedenleri bulunmaktadır. İşletme içi nedenler genellikle yönetim kademesinden kaynaklanan ve denetlenebilecek ve çözümlenebilecek nedenlerdir. İşletme dışı nedenler ise yönetimin kontrol edemediği problemlerdir. Makro düzeyde ekonomik nedenler; pazarın durumu, ülkenin siyasi yapısı, kırılganlığı gibi durumlar işletme dışı nedenler arasında sayılabilir. İşletmelerin bu iki faktörü iyi analiz edip öngörülü davranması işletmenin sıkıntılı süreçleri daha az yara ile atlatmasını sağlar.

Finansal başarısızlığın önceden tahmin edilmesi ile işletmelerin yönetim kurulu daha doğru kararlar verebilir. İşletmeler doğru kararların uygulamaya konulması ile finansal sıkıntının üstesinden gelebilirler. Finansal sıkıntının aşılması sadece ilgili işletmeyi değil işletmenin dolaylı veya dolaysız yönden irtibatlı olduğu tüm paydaşları olumlu yönde etkileyebilmektedir.

Bu öneminden dolayı finansal başarısızlık tahmini bu alanda yıllar boyunca araştırılmış ve çeşitli modeller geliştirilmiştir. Finansal başarısızlık tahmininde ilk dönemler tek değişkenli ve çok değişkenli modeller oluşturulmuştur. Teknoloji devriminin yaşanması ile geleneksel modellere alternatif modeller geliştirilmiştir. Bu alternatif modellerin başında makine öğrenmesi, yapay zekâ teknikleri gelmektedir. Yapay zekâ tekniklerinde, geleneksel istatistikî tekniklerde olan varsayımların kullanımına gerek yoktur. Bundan dolayı yapay zekâ tekniklerini sınırlayıcı herhangi bir durum oluşmamaktadır. Yapay zekâ teknikleri çok sayıda değişkenin karmaşık bir yapı içinde bulunduğu durumlarda başarılı sonuçlar vermektedir. Bu sebeple yapay zekâ teknikleri başta finans alanında olmak üzere birçok alanda kullanılmaktadır.

Bu çalışmada geleneksel istatistikî modeller yerine yapay zekâ modelleri ile işletmelerin finansal başarı durumları öngörülmeğe çalışılmıştır. Çalışma dört bölümden oluşmaktadır. Birinci bölümde finansal başarısızlık teorik olarak açıklanmıştır. İkinci bölümde finansal başarısızlık tahmininde kullanılan modeller açıklanmıştır. Üçüncü bölümde literatür araştırması yapılmıştır. Dördüncü bölümde ise yapay zekâ teknikleri kullanılarak modeller oluşturulmuş ve uygulama gerçekleştirilmiştir.

Uygulama bölümünde, Borsa İstanbul'da işlem gören ve daha önce görmüş olan imalat sanayi sektörlerindeki işletmelerin 2008-2016 yılları arasındaki verileri uygulamaya dahil edilmiştir. Çalışmada kullanılan bağımsız değişkenler, işletmelerin bağımsız denetçilerden geçmiş finansal tablolarından elde edilmiş oranlardır. 26 değişken kullanılmıştır. Başarısız sınıfına alınacak işletmeler için beş şart belirlenmiş olup bu şartlardan bir veya daha fazla şarta uyan işletme başarısız sayılmıştır.

İşletmelerin başarısızlığa uğramadan 1, 2 ve 3 yıl öncesinden başarı durumu tahmin edilmeye çalışılmıştır. Tahmin modellemesi için üç yapay zekâ tekniği kullanılmıştır. Bunlar; yapay sinir ağları, destek vektör makineleri ile yapay sinir ağları ve destek vektör makineleri yöntemlerinin bir arada kullanıldığı topluluk öğrenme yöntemidir. Uygulama bölümünün ardından sonuç ve değerlendirme son bölümde yer almaktadır.

1.2. FİNANSAL BAŞARISIZLIK KAVRAMI

Şirketlerin finansal durumlarının tespiti uzun yıllardır ekonomi ve finans gündemini meşgul etmektedir. 1930'lardan önce kredi veren kuruluşlar müşterilerinin finansal durumlarını öğrenmek istemişlerdir. Bunun için ajanslar kurulmuş ve bu ajanslar tüccarları niteliksel olarak ölçmüşlerdir. 1930'larda ise firmaların finansal durumları niceliksel olarak ölçülmeye başlanmıştır. Daha sonraki yapılan çalışma ve ölçümlerde de başarılı ve başarısız firmalar arasında önemli farklar ortaya çıkmıştır. Bu güçlü farklar özellikle firmaların finansal oranlarında daha belirgindir (Altman, 1968: 590).

İşletme başarısızlığı işletmenin mali yükümlülüklerini yerine getirememesi ya da artan bir şekilde yerine getirmede zorluk çekmesi olarak tanımlanabilir. Operasyonel olarak bir firmanın iflas, temerrüt, aşırı banka hesapları veya hisse senedi temettüsünün ödenememesi durumlarıyla yüz yüze kalması başarısızlık olarak değerlendirilmiştir (Beaver 1966: 71).

6102 sayılı Türk Ticaret Kanunu'nda ise finansal başarısızlık aşağıdaki şekliyle yer almaktadır:

“Cari bilançodan, sermaye ile kanuni yedek akçeler toplamının yarısının zarar sebebiyle karşılıksız kaldığı anlaşılırsa, yönetim kurulu, genel kurulu hemen

toplantıya çağırır ve bu genel kurula uygun gördüğü iyileştirici önlemleri sunar. Son yıllık bilançoya göre, sermaye ile kanuni yedek akçeler toplamının üçte ikisinin zarar sebebiyle karşılıksız kaldığı anlaşıldığı takdirde, derhâl toplantıya çağrılan genel kurul, sermayenin üçte biri ile yetinme veya sermayenin tamamlanmasına karar vermediği takdirde şirket kendiliğinden sona erer.” (TTK, Madde 376).

Finansal başarısızlık ve iflasın yer aldığı kanun maddesinde görüldüğü üzere Türk hukuk sisteminde kanun koyucu finansal başarısızlık durumunda işletmenin yönetim kurulunu icracı makam olarak sorunun tespit edilmesi ve çözüm bulması konusunda sorumlu tutmuştur. Genel kurul işletme faaliyetlerinin devamı konusunda karar verme merciidir. Fakat her iki kurulunda yetkileri ilgili kanun maddesi ile sınırlandırılmış olup burada paydaşlar ve ekonomik sistemin korunması amaçlanmıştır (Söylemez ve Türkmen, 2017: 271).

İşletmeler, muhasebenin “Kişilik Kavramı” gereği işletmenin sahip veya sahiplerinden, yöneticilerinden, personelinden ve diğer ilgililerden ayrı bir kişiliğe sahiptir ve tüzel kişilikleri ile tanınır. Dolayısı ile işletmelerin finansal başarısızlığı, tüzel bir kişilik olan işletmenin başarısızlığı olarak kabul edilir. (Selimoğlu ve Orhan, 2015: 25). Literatürde finansal başarısızlık için yaygın olarak çeşitli terimler kullanılmaktadır. Bunlar; başarısızlık, temerrüde düşme, iflas, mali yetersizlik şeklindedir. Her ne kadar bu terimler birbirinin yerine kullanılsa da temelde belirgin farklar mevcuttur Bunlar (Edward, 2006: 4-5):

- **Başarısızlık:** Ekonomik ölçütlere göre yapılan yatırımın risk değerlendirmesinde dikkate alınan getiri oranının, benzer yatırımlardaki mevcut oranlardan önemli ölçüde ve sürekli olarak düşük olduğu anlamına gelir.
- **Mali yetersizlik:** Mali yetersizlik yani borcunu ödeyememe durumu olumsuz performanslardan bir diğeridir ve daha teknik bir terimdir. Bir borçlunun mevcut yükümlülüklerini yerine getirememesi ve likidite eksikliğini ifade etmesi durumunda teknik olarak mali yetersizlik hali ortaya çıkar.
- **Temerrüde düşme:** Temerrüt, borçlunun alacaklı ile yapılan bir anlaşmanın şartını ihlal etmesi ve yasal işlem için gerekçe olması

durumunda gerçekleşir. İşletmenin kendisine borç veren tarafa zamanında borcunu ödeyememe durumu ve akabinde yasal işlemlerle yüz yüze kalma durumu şeklinde de adlandırılabilir.

- İflas: İşletmenin mali yetersizlik sonrası yükümlülüklerini yerine getirememesi sonucunda mahkeme yoluyla resmi olarak ilan edilmesidir. Yargının kararı sonrası işletme tasfiye edilebileceği gibi bir düzenlemede yapılabilecektir.

Finansal açıdan başarısızlık türleri aşağıdaki gibi tanımlanmaktadır:

- Negatif veya Düşük Kar: İşletmenin karlılığı negatif veya düşük olduğunda işletme finansal/mali başarısızlığa uğrayabilir. İşletmenin faaliyetleri sürekli zararlar neticelenirse bu işletmenin piyasa değeri düşecektir (Aydın vd., 2017: 326).
- İşletmenin Teknik Likiditesini Kaybetmesi: İşletme yöneticisinin iyi niyetli çalışmasına rağmen vadesi gelen yükümlülükleri yerine getirememesi durumuna finansal yönetimde işletmenin teknik likiditesini kaybetmesi denir (Ceylan ve Korkmaz, 2015: 374).

Yukarıda verilen tanımlar dışında literatürde yapılan başarısızlık kavramı farklı çalışmalarda Tablo 1.1’de verildiği gibi tanımlanmıştır:

Tablo 1.1. Literatürde Finansal Başarısızlık (Salur, 2015:9)

Araştırmacı	Araştırma Tarihi	Finansal Başarısızlığı Nasıl Tanımladığı	Başarısızlık Kriteri
Beaver	1966	Başarısızlık	Vadesi gelen finansal yükümlülükleri karşıla-yamama. Başarısızlık tanımı içinde kabul edilen olaylar ise; tahvil faizlerinin ödenememesi. Karşılıksız çek düzenlenmesi, imtiyazlı hisse senetlerine temettü dağıtılmaması.
Altman	1968	İflas	Yasal olarak iflas başvurusunda bulunmuş olma ve kayyum atanmış ya da ulusal iflas yasası hükümlerince reorganizasyon hakkı verilmiş işletmeler.
Wilcox	1970	Başarısızlık	Belirlenen iki nokta arasında işletmenin varlıklarında meydana gelen azalma.
Edminister	1972	Başarısızlık	Beaver (1966) ile aynı kriterleri kullanmıştır.
Blum	1974	Başarısızlık	Vadesi gelen borçların zamanında ödenememesi. Alacaklılar ile borçların azaltılması konusunda anlaşma talebinde bulunma ve iflas sürecine girme.
Elam	1975	İflas	Toplam yükümlülüklerin toplam varlıkların gerçeğe uygun değerini aşması, ulusal iflas yasası hükümlerince reorganizasyon hakkı

Deakin	1976	Başarısızlık	İflas etme veya alacaklıların isteği üzerine tasfiye sürecine girme.
Altman, Haldeman ve Narayanan	1977	İflas	Yasal olarak iflas başvurusunda bulunmuş olmak
Van-Frederikslust	1978	Başarısızlık	Borçlarını zamanında ödeyemeyerek teknik olarak nakit aciziyetine düşmek

Tablo 1.1. Literatürde Finansal Başarısızlık (Devamı) (Salur, 2015:9)

Araştırmacı	Araştırma Tarihi	Finansal Başarısızlığı Nasıl Tanımladığı	Başarısızlık Kriteri
Norton ve Smith	1979	İflas	Beaver (1966) ve Elam (1975) ile aynı kriteri kullanmıştır.
Dambolena ve Khoury	1980	Başarısızlık	Altman (1968) ile aynı kriterleri kullanmıştır.
Ohlson	1980	İflas	Yasal olarak iflas başvurusunda bulunmuş olmak
Göktan	1981	Başarısızlık	İşletmenin borcunu ödeyemeyecek duruma düşmesi.
Zavgren	1982	İflas	Yasal olarak iflas başvurusunda bulunmuş olmak
Taffler	1982	Başarısızlık İflas	Tasfiye, alacaklıların isteği üzerine tasfiye ve mahkeme kararıyla faaliyete son vermiş olmak.
Zmijewski	1983	İflas	Yasal olarak iflas başvurusunda bulunmuş olmak
Casey ve Bartczak	1985	İflas	Yasal olarak iflas başvurusunda bulunmuş olmak
Aktaş	1993	Başarısızlık	Üç yıl üst üste zarar etmiş olma veya yaşanan mali kriz nedeniyle üretimin durdurulması.
Yıldız	1999	Başarısızlık	İflas etmiş olma, borçların ertelenmesi ödenememesi. Üretimin durdurulması. Üç yıl üst üste zarar etmiş olma, şirket kurtarma yasası gereğince kurtarılmış olma, borçların aktif aşması, sermayenin yarısının veya 2/3'sinin kaybolması.
Altman, Zhang ve Yen	2010	Başarısızlık	İki yıl üst üste zarar Son yılda zarar eden fakat özkaynaklar toplamı, kayıtlı sermayenin altına düşen işletmeler Denetçilerin raporunda işletmeye ait sürekliliği hakkında şüpheye yer verilmesi.
Torun	2007	Başarısızlık	İki yıl üst üste zarar etmiş olma, borsada tahtasının kapanması, faaliyetlerin durması, iflas etmiş olma.
Beaver Correia. McNichols	2009	İflas	Bir yıl içerisinde yasal olarak iflas başvurusunda bulunmuş olmak.
Wu. Gaunt ve Gray	2010	İflas	Bir yıl içerisinde yasal olarak iflas başvurusunda bulunmuş olmak.
Özdemir	2011	Başarısızlık	Son iki yıl içinde zarar etmiş olma durumunu, defter değer esaslı; hisse senedi fiyatının son iki yıl içindeki değişiminin, hisse senedinin işlem gördüğü borsanın genel endeksindeki değişim karşısındaki bağıl durumunu. Piyasa değeri esaslı başarısızlık kriteri olarak almıştır.
Kılıç	2012	Başarısızlık	İflas İMKB gözüde pazarında yer almak Aktif tutarının %10'unu kaybetmiş olması İki yıl üst üste zarar etmiş olmak.

İşletmelerin de canlı varlıklar gibi bir yaşam evresi vardır. Bu evre içinde işletmeler gerek işletme içi faktörlerden gerekse dış faktörlerden dolayı zamanla

finansal anlamda sıkıntı yaşayabilmektedir. Finansal sıkıntılar daha öncesinden sinyal verirler. Sinyaller anlamlıdır ve bu anlamları yorumlamak gerekmektedir. Mali sıkıntılardan işletmenin az zararla kurtulabilmesi önemlidir. Mali sıkıntının, iyi bir finansal plan ve bu planı uygulayabilecek teknik donanıma sahip yöneticilerin olması ile aşılması mümkündür. Aksi durumda mali sıkıntılar ile baş edemeyen işletmeler iflas durumuyla karşılaşacaklardır. Şekil 1.1’de işletmelerin başarısızlığının oluşum süreci görülmektedir.



Şekil 1.1. İşletmelerde Başarısızlığın Gerçekleşme Süreci (Aydın vd., 2017)

Şekil 1.1’de görüldüğü üzere sonsuz varsayılan normal faaliyet süresince işletmenin finansal sorunlarla karşılaşma durumunda ilk aşama sorunu kabul etme ve içsel önlem alma durumudur. İçsel önlemler faaliyetlerin değiştirilmesi ya da iş organizasyonunun yeniden düzenlenmesi şeklinde olabilir. Bu eylemler finansal sorunu çözmeye yetersiz ise işletme dışsal önlemlere yönelmektedir. Dışsal önlemler arasında işletmenin türüne ve büyüklüğüne bağlı olarak anlaşmalar, iyileştirme, şube

kapatma, birleşme ve satılma eylemleri mevcuttur. Bu dışsal önlemler sonucunda işletme ya normal faaliyetlerine geri dönüş yapar ya da iflas ve tasfiye ile karşılaşır.

1.3. FİNANSAL BAŞARISIZLIĞIN NEDENLERİ

İşletmelerin varlığını sürdürebilmesi ve hedeflerine ulaşması finansal yapılanmaları ile yakından ilgilidir. Ekonomilerdeki makroekonomik faktörler reel sektörün temel taşları olan işletmeleri finansal krizlere dolayısıyla başarısızlığa itmektedir. İşletmeler kendi faaliyetlerinden doğan finansal işlemleri belirli bir plan içerisinde sürdürememesi durumunda krizlere girmesi muhtemeldir. İşletmelerin kendi yapısından kaynaklanan ve ekonominin içindeki koşullar nedeniyle finansal durumunda olumlu ya da olumsuz değişiklikler olabilir. Bu değişikliklerin titizlikle değerlendirilememesi durumunda da işletmeleri başarısızlık beklemektedir (Usta, 2014: 189).

İşletme finansal başarısızlığı, ülkeler bağlamında sosyo-ekonomik sonuçları açısından önemli bir sorundur. Son yıllarda finansal başarısızlığa uğrayan işletme sayısında hem Türkiye’de hem de dünyada bir artış olduğu gözlenmektedir. Bu artış genel olarak ülkelerin içinde olduğu ekonomik durgunluğa, enflasyonu önlemek için uygulanan sıkı para ve kredi politikasına, yüksek faiz oranlarına ve işletmelerin artan finansal risk yapılarına bağlanmaktadır (Akkaya vd., 2009).

Bunlara ek olarak finansal başarısızlığı artıran ya da etkileyen faktörler arasında önemli bir etmen de işletme içi sorunlardır. İletişim sorunları, büyüme sorunları, proje bazlı hatalar, yönetsel sorunlar, üretim ve üretim hataları, pazarlama departmanının yanlış stratejileri, yetersiz iç kontrol sistemi ve aşırı finansal ve faaliyet kaldıracı işletmeleri başarısızlığa sürükleyen etkenlerdir (Aktaş vd., 2003: 2).

İşletmelerin başarısızlığa uğrama nedenlerini genel olarak aşağıdaki şekilde sıralamak mümkündür (Akgüç, 1998: 947-948):

- İşletmenin satış hacminin yeterli bir düzeye ulaşamaması,
- Faaliyet giderlerinin aşırı derecede yüksek olması,
- Firmanın alacaklarını zamanında tahsil edememesi,
- Stok yönetimindeki sorunlar,

- Aşırı borçlanma,
- İşletmenin kuruluş yerinin hatalı seçilmesi,
- Sektördeki diğer işletmeler ile rekabetin zayıf olması,
- Likidite yetersizliği, yükümlülüklerin zamanında yerine getirilmemesi.

Aydın vd. (2017) ise işletmelerin başarısızlığa uğrama nedenlerini aşağıdaki gibi sıralamışlardır:

- Aşırı büyüme sonucunda öz sermayenin yetersiz kalması,
- Aşırı maliyet artışları ve finansman giderlerinin artması,
- Duran varlıklara gerektirdiğinden çok yatırım yapılması ve varlıkların bir bölümünün atıl kalması,
- Ekonomik ve çevre koşullarının değişmesi ve doğal afetler,
- Etkin bir nakit yönetim politikasının izlenmesini sağlayacak tekniklerin kullanılmaması nedeniyle, işletmenin nakit sorumluluklarını yerine getirememesi veya gereğinden fazla nakit bulundurması,
- Dünyada, ülkede ve endüstride ortaya çıkan gelişmelerin önünde yer alınamaması veya en azından bu gelişmelerin izlenememesi,
- İyi bir borçlanma politikasının oluşturulamaması,
- Ekonomide çeşitli krizlerin yaşanması,
- İşletme yönetiminin niteliksiz olması ve personel devir hızının yüksek olması.

İşletmelerin finansal başarısızlıkları işletmenin hayat evresi içinde faaliyetlerinin her aşamasında çıkabilmektedir. Genel olarak yukarıda açıklanan başarısızlık nedenleri işletmelerinin içsel durumlarından kaynaklanan nedenler ve işletmelerin kontrol edemediği dışsal nedenler olmak üzere iki grupta toplanabilir.

İşletmelerin mali başarısızlığı birçok faktöre bağlı değişebilmektedir. Yapılan bazı çalışmalarda araştırmacılar işletmelerin başarısızlığını Tablo 1.2’de görüldüğü gibi tespit etmişlerdir (Türksoy, 2007: 101).

Tablo 1.2. Mali Başarısızlığa Etki Eden Etmenler (Türksoy, 2007)

Araştırmacı	Yıl	Başarısızlık Etmenleri
Altman	1984	Faiz Oranları, Enflasyon, Enflasyonu Düşürücü Politikalar, Ekonomik Durgunluk
Norman	1991	Maliyet Yapısı, Rekabet
Laitinen ve Laitinen	1998	Ekonomik Durgunluk, Milli Gelir Dağılımının Bozulması, Faiz Oranları
Hudson	1997	Arz ve Talep
Nucci	1999	İşletme Ölçeği
Stokes ve Blackburn	2002	Nakit akımı ve Vergi Sorunları
Lensberg ve Diğ.	2006	Yüksek Maliyetler, Düşük Talep, Ekonomik Durgunluk

Tablo 1.2’de görüldüğü üzere başarısızlık etmenlerinin bazıları işletmenin kontrolü dışında gelişen etmenler olurken, işletme ölçeği, nakit akımı ve maliyet yapısı gibi etmenler ise işletmenin kontrol edebileceği etmenlerdir. İşletmeler bu etmenleri doğru analiz edip gerekli müdahaleleri yapabilmeli ve mutlaka bir plan dâhilinde hareket etmeleri gerekmektedir.

1.3.1 İşletme içi nedenler

İşletmeler de organizmalar gibi büyürler. Çoğunlukla büyümelerini destekleyecek oranda öz kaynaklarını artıramazlar yani borçla büyürler. Bunun neticesinde işletmede öz kaynak sıkıntısı ve yetersizliği başlar. İşletmeler finansal kaldıraçtan yararlanarak büyümelerini finanse ederler. Finansal kaldıraç derecesinin artması ile işletmelerin karşılaştıkları sorunlar da artabilmektedir ve bu durum ise işletme karlılığı üzerinde olumsuz etki yapabilmektedir. Ayrıca işletme kuruluş yerinin hatalı seçilmesi, müşteri beklenti ve tutumlarının göz ardı edilmesi, alacak tahsilatının etkili yürütülememesi, sınırlı sayıda alıcı ve satıcı ile çalışılması, duran varlıklara aşırı yatırım yapılması, teknolojinin takip edilmemesi ve yeterince Ar-Ge

çalışmalarının yapılmaması gibi içsel nedenler işletmeleri başarısızlığa uğratabilir (Sayılğan, 2013: 492-493).

İçsel nedenler daha çok işletmenin yönetiminden kaynaklanan ve denetlenebilecek nedenlerdir. İçsel nedenler yönetimin, beceri, tecrübe ve teknik yaklaşımlarla üstesinden gelinebilecek nedenler iken dışsal nedenler için aynı şeyleri söylemek mümkün değildir. Etkili olmayan üretim yöntemleri, pazarlamadaki hatalar, yanlış satın almalar ve personel politikaları işletmeleri başarısızlığa iten içsel nedenler arasında sayılabilir. İşletmelerin başarısızlıkları ile yapılan ve iki gruba ayrılan araştırmalara ait ilgili yüzdelik oranlar Tablo 1.3’de gösterilmiştir (Ceylan ve Korkmaz, 2015: 375):

Tablo 1.3. Başarısızlık Nedenleri ve Yüzdeleri (Ceylan ve Korkmaz, 2015)

1. Araştırma	
Başarısızlık Nedenleri	Başarısızlık Yüzdeliği
İhmal	2,0
Hile	1,5
Doğal Afetler	0,9
Yönetim Yetersizliği	93,1
Bilinmeyen	2,5
2. Araştırma	
Başarısızlık Nedenleri	Başarısızlık Yüzdeliği
Endüstride Beklenmeyen Gelişmeler	20
Yönetim Yetersizliği	60
Doğal Afetler	10
Diğer	10

Tablo 1.3’de görüldüğü üzere her iki araştırma sonucunda da başarısızlığın nedenleri arasında görünen yönetim yetersizliği yüzde 93,1 ve yüzde 60 ile en büyük paya sahiptir. İşletmelerde finansal yapının zayıflamasının en önemli nedenlerinden biri de yönetsel hatalardır. İşletmenin bir anda başarısız olması söz konusu değildir. Başarısızlığa doğru yol alan işletme, sinyalleri öncesinde vermeye başlar. Sinyalleri doğru yorumlayabilen, önlemler alabilen, a,b,c... gibi planları olan yöneticiler bu sıkıntılı dönemleri daha az zararla atlatabilmektedir. Yöneticide bulunması gereken özelliklerden yoksun bir yönetimde başarısızlık kaçınılmazdır.

İşletmeleri başarısızlığa götüren yönetim hataları aşağıdaki gibi sıralanabilir (Akgüç, 1998: 948-949):

- Finansal planlamanın yetersiz oluşu,
- Sabit giderlerin, firmanın taşıma gücünün üstünde bir yük oluşturması,
- Yükümlülüklerin yerine getirilmesi konusunda gereken özenin gösterilmemesi, önlemlerin alınmaması,
- Departmanlar arası iletişim sorunu. Satış, üretim ve finans bölümleri arasındaki eşgüdümün sağlanamaması,
- Yeni ürünler geliştirilememesi,
- İşletme faaliyetlerinin yeterince çeşitlendirilememesi,
- Sektördeki gelişmelerin takip edilmemesi,
- Müşteriler hakkında yeterince araştırma yapmadan kredili satışların yapılması,
- Pazar araştırmalarına önem verilmemesi.

İşletme yöneticileri başarılı olmak için ya da yukarıda sıralanan başarısızlık durumlarına düşmemek için finansal analiz yapmaları gerekmektedir. Bu analizlerin yapılmasının başlıca amacı, firmanın başarı durumunu (performans derecesi) tam olarak değerlendirip ortaya koyabilmektir. Finansal analiz, işletme yöneticileri açısından önemli bir araçtır ve önemli finansal konuların gerçekleştirilmesinde yönetime büyük kolaylık sağlamaktadır (Özdemir, 2016: 22).

İşletme yöneticileri açısından finansal başarısızlığın en yaygın nedenleri arasında zayıf yönetim ve otokratik liderlik gösterilmektedir (Xu ve Wang, 2009: 366). İşletmelerin sahip olduğu zayıf yönetim organizasyonları ileriye dönük finansal strateji oluşturamazlar ve bu nedenle her an bir başarısızlıkla karşılaşabilirler. Ülke, paydaş, sektör, sosyo-ekonomik ve politik konjonktürünü analiz edemeyen işletme yöneticileri kendi işletmelerini başarısızlığa sürükleyebilecekleri gibi kendileriyle ticari ilişki içinde olan firmaları da dolaylı veya dolaysız olarak zor durumda bırakabilirler. İşletmelerin yöneticilerinin otokratik lider türünden olması durumunda işletme finansal başarısızlığa daha yakın pozisyonadadır. Otokratik liderler, tek yönlüdür kimseyi dinlemezler. Diğer taraftan, bu tarz yönetici türüne sahip işletmelerde lider hedefsiz ilerlediğinde işletme paydaşlarının zarar görmesine

sebebiyet verirler Otokratik liderler yönettikleri kişilere karşı bir üstünlük duygusuna sahiptirler ve çalışanların veya astların duygularını ve düşüncelerini çok fazla dikkate almadıkları için iş tatminsizliği maksimum, işletmeye olan kurumsal bağlılık minimum seviyededir (Eryeşil ve İraz, 2012: 131). İş tatminsizliği maksimum olan ve örgüte bağlılığı az olan işletmelerin ayakta kalması için gerekli olan finansal oranlar hiçbir zaman istenen seviyede olamaz.

1.3.2. İşletme dışı nedenler

İşletme dışı etmenler yöneticinin kontrolü dışında gelişir. İşletme her ne kadar bu etmenleri azaltma imkânına sahipse de tümünden sıfırlaması mümkün değildir. İşletme dışı faktörlerin başında girdilerde meydana gelen darlıklar veya büyük fiyat değişiklikleri gelmektedir. Bu değişiklikler beraberinde maliyetlerde artışa, işletmede çalışan personel sayısının azaltılmasına, sosyal imkânların kısıtlanmasına, çıkarılan personelin iş yükünün mevcut çalışan personele yüklenilmesi olarak bir dizi olumsuz tedbirleri getirecektir (Çelik, 2009: 11). Dış etmenler arasında sayılabilecek ekonomin büyüme hızı, sektördeki değişiklikler, tüketicinin tercih ve tutumlarındaki değişiklikler, pazarın yapısındaki değişiklikler işletmenin karlılığını ve pazardaki gücünü etkilemektedir (Sharma ve Mahajan, 1980: 82).

İşletme başarısızlığına neden olan çevresel faktörler aşağıdaki gibi sıralanabilir:

1.3.2.1. Toplumsal çevre

İşletmelerin başarısızlığı üzerinde etkili olan çevresel faktörlerden biri toplumsal çevredir. İşletme ile doğrudan ve dolaylı olarak ilişkili tüm sosyal, kültürel ve beşeri unsurların işletme üzerindeki çok yönlü etkileşimini ele alır. Buna göre işletme çalışanları, müşteriler, alışkanlıklar, örf adetler, toplumsal normlar vb. gibi pek çok unsur işletmelerin üretim ve yönetim yapısında belirleyici unsur olabilir. (Çoban, 2014: 7-8). İşletme yöneticilerinin mutlaka faaliyet gösterdiği çevreyi tanımaları ve ona göre bir strateji yürütmeleri gerekmektedir. İşletmenin başarısını artıracak önlemler ve planlar bu çevre dahilinde alınmalıdır.

İşletmeler başarılı olabilmek için faaliyet gösterdiği toplumun istek ve beklentilerine uygun davranarak faaliyetlerini bu doğrultuda devam ettirmelidir. Toplumun ekonomik ve sosyal yapısına uygun, kaliteli mal veya hizmet üretmek, toplumun sahip olduğu değerlere önem vererek toplumla sürekli etkileşim ve iletişim halinde tüketicilere saygılı ve çevreye duyarlı olmak bu noktada toplumsal çevrenin işletmelerden beklentilerinden bazılarıdır (Salur, 2015: 17).

1.3.2.2. Yasal ve politik çevre

İşletmeler yasal kurallara göre kurulur ve faaliyet gösterir. İşletmenin hayat evresi içinde tüm ilişkilerinde bir hukuki boyut mevcuttur. İşletmelerin faaliyetleri aşamasında bağlı olduğu yasal düzenlemelere uymaması durumunda işletmelere cezai yaptırımlar uygulanabilir. İşletmelerin bu cezai yaptırımlarla karşılaşması tüketici, toplum, sosyal çevre tarafında uygun karşılanmaz ve sonrasında başarısızlık söz konusu olabilir (Kılıç 2011: 18).

1.3.2.3. Ekonomik çevre

Ekonomik çevre işletmenin içinde bulunduğu sektör ve ekonomilerde ortaya çıkan gelişmeleri kapsar. Ekonomik çevre kavramında işletmenin faaliyet gösterdiği ülkedeki ekonomik konjonktürün, ekonomik istikrarın, işletmenin faaliyette bulunduğu piyasa türünün, toplumsal ve bireysel ekonomik tercihlerin, uluslararası ekonomideki gelişmelerin, ekonomik göstergelerin ve beklentilerin işletme faaliyetleri üzerinde yarattığı etkiler ele alınır (Çoban, 2014: 7). İşletmeleri faaliyet gösterdiği sektördeki gelişmeler ve bağlı olduğu ekonomik sistemdeki dalgalanmalar etkiler. Devlet yönetiminin benimsemiş olduğu para politikası, maliye yönetimi ve sermaye piyasası işletmelerin de yönetimine bağlı olarak mali yapılarını ve faaliyetlerini farklılaştırır. Siyasi iktidarların yönetim biçimlerine göre işletmelerin başarısını etkileyen faktörler şu şekilde sıralanabilir (Öztürk, 2002: 20):

- Milli gelirin yapısı
- Enflasyonist ve deflasyonist eğilimler
- Ekonominin gelişme devresinin durumu
- Hükümetin ekonomi politikaları

1.3.2.4. Doğal çevre

İşletmelerin kuruluş yerinin, ölçeğinin ve hareket alanının belirlenmesinde etkili olan iklim, toprak yapısı, coğrafik durumlar, ulaşım, altyapı, enerji doğal çevrenin unsurlarıdır. İşletmelerin faaliyetlerini sürdürebilmesi için ihtiyacı olan her türlü kaynağı çevresinden tedarik eder. Bu kaynaklar hammadde olabileceği gibi üretimin devam edebilmesi için gerekli enerji kaynağı da olabilir. Doğaya gerekli hassasiyetin gösterilmemesi sonucu oluşan çevre kirliliği ve beraberinde gelen küresel ısınma benzeri etkilerle kaynaklar değişmeye, azalmaya hatta yok olmaya uğrayabilir. Faaliyetlerin sürdürebilmesi için son derece önemli bir kaynağa doğal etkenler nedeniyle ulaşımadaki zorluk, işletmeleri sıkıntıya sürükleyecek ve başarısızlık söz konusu olabilir.

Doğal etkenler, işletmenin faaliyetini sürdürmesine engelleyen deprem, su basması, heyelan gibi işletmenin kontrolü dışında gelişen olaylardır. Bu etkenler, işletmenin üretimini veya dağıtımını yapmasına engel olabileceği gibi hammadde ve ara ürünlere ulaşmasına da engel olabilir. Doğal etkenlerin tahmin edilmesi mümkün değildir ve onun için diğer finansal başarısızlık nedenlerinden ayrılırlar. İşletmeler, tüketicileri, finansal piyasaları, rakipleri, sektörü iyi analiz ederek mali başarısızlığı öngörebilirler. Ancak doğal etkenlerin tahmin edilmesinin mümkün olmayışı, işletmeleri bu konuda çaresiz kılmaktadır (Selimoğlu ve Orhan, 2015: 27-28).

Ayrıca enerji kaynağındaki azalma veya enerji kaynağına ulaşımadaki zorluklar işletmelerin faaliyetlerini sürdürmesine engel olabilecek durumlardır. Üretimin tam kapasite ile çalışmaması karlılığı düşürecek çevrenin talebine cevap vermede sıkıntı yaşanabilir. Bu sıkıntılar tüketici nezdinde kötü itibar bırakır. Bu zincirleme sıkıntı durumları neticesinde finansal sıkıntı ve başarısızlık oluşur. Devletlerin, toplumun ve işletmelerin mutlak suretle üretiminin girdisi olan enerji kaynaklarını koruması gerekmektedir.

1.3.2.5. Teknolojik çevre

Teknoloji, işletmelerde sürekliliğin devamı ve verimli çalışma için üretim ve yönetimde makinelerin kullanılması süreci olarak tanımlanabilir. Bu süreçte emek yoğun sistemden makine sistemine geçiş söz konusudur. Yeni bilgi, teknik, araç-gereç ve bilgisayar sistemlerinin kullanılması ile toplumun talep ettiği mal ve hizmetler daha kaliteli ve düşük maliyetle sunulmaktadır. Teknolojiyi kullanma işletmeler için

maliyetli olmaktadır. Eđer iřletme teknoloji üretmiyorsa satın almak ya da kiralamak zorundadır. Buradaki sakınca ise iřletmenin dışarıya bağımlı olmasıdır. Günümüzde teknoloji hızla gelişmektedir. Kullanılan makinelerin çok kısa sürede demode olması iřletmeleri sıkıntılı bir duruma sokabilmektedir. Belirtilen nedenlerden dolayı mali gücü yetersiz iřletmeler gerek iřletme içi Ar-Ge faaliyetlerine gerekse teknoloji satın almaya gereken önemi vermemektedir. İřletmelerin teknolojiye önem vermemesi, özellikle küreselleřen dünyamızda iřletmelerin rakipleri ile sektörde mücadele edememelerine ve iflas etmelerine neden olabilir (Karacan ve Savcı, 2011: 48-49).

1.4. FİNANSAL KRİZ VE FİRMA BAŞARISIZLIĞI

1.4.1. Finansal kriz

Finansal krizler iřletmeler üzerinde yıkıcı bir güç oluşturmakla beraber piyasaların ekinliğini azaltmaktadır. Finansal kriz ile ilgili çeşitli tanımlar yapılmıştır. Mishkin (2007), finansal krizi varlık fiyatlarındaki sert düşüşler, piyasadaki büyük aksamalar ve sektörlerde faaliyet gösteren firmaların mali sıkıntı, finansal başarısızlık içine girmeleri olarak tanımlamıştır. Bir başka tanımda, finansal kriz, bir mal, hizmet, üretim faktörü veya finans piyasasındaki fiyat ve/veya miktarlarda kabul edilebilir bir deęişme sınırının ötesinde gerçekleşen şiddetli dalgalanmalar olarak tanımlanmıştır (Pıçak vd., 2009). Döviz ve hisse senedi piyasaları gibi finans piyasalarındaki şiddetli fiyat dalgalanmaları veya bankacılık sisteminde bankalara geri dönmeyen kredilerin aşırı derecede artması sonucunda yaşanan ciddi ekonomik sorunlar finansal kriz olarak kabul edilebilir (Kibritçioęlu, 2001: 2).

Krizin temel unsur ve özellikleri aşağıdaki gibi sıralanabilir (Aktan ve Şen, 2001: 1-2):

- Kriz, önceden öngörülemeyen bazı gelişmelerin gerçekleşmesi sonucu makro düzeyde devletleri, mikro düzeyde ise firmaları sarsacak düzeyde sonuçların ortaya çıkmasıdır. Aniden ve beklenmedik bir anda ortaya çıkan olumsuz gelişmeleri kriz olarak adlandırmak doğrudur. Normal faaliyet süreci içinde meydana gelen her soruna kriz demek doğru tanımlama

değildir. Kriz, beklenmedik biçimde ortaya çıkan ‘ciddi bir sorun’ olarak gerçekleşmektedir.

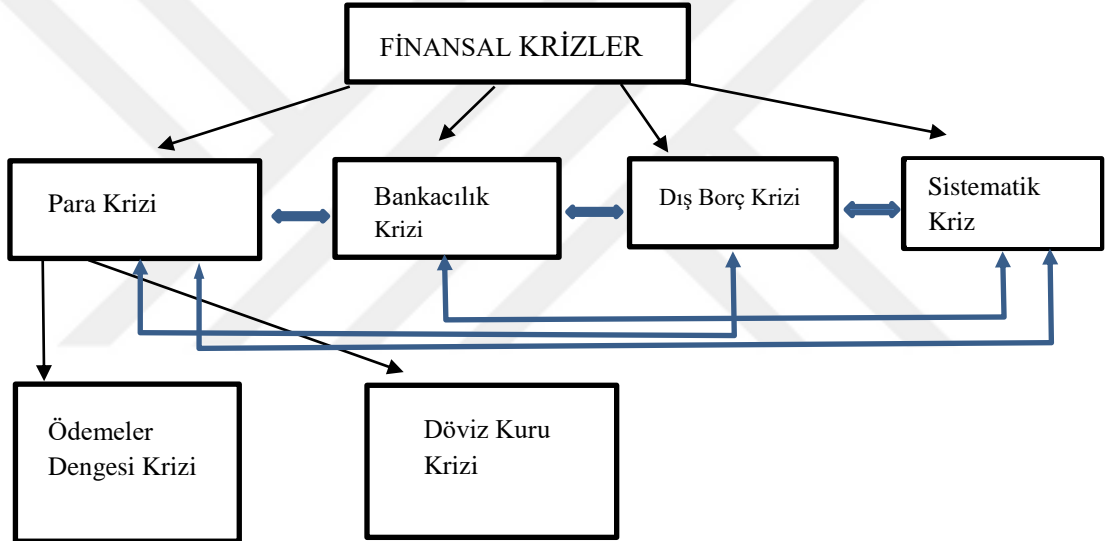
- Ekonomik kriz her ne kadar sinyaller verse de önceden tahmin edilmesi zordur ve bir anda ortaya çıkmaktadır.
- Krizler işletmeler için tehlike ve sıkıntı oluştursa da aynı zamanda yeni fırsatların doğmasına da sebep olmaktadır. Bundan dolayı krizi sadece olumsuz kavram olarak düşünmek yanlıştır.
- Krizler, kısa veya uzun sürede etkili olabilmektedir. Krizlerin işletmelere etkisinin uzun ya da kısa süreli olması, işletme yöneticilerinin krizlere karşı koyabilecek önlem planlarının olması ve bunları uygulama düzeyine bağlıdır.
- Krizlerin diğer bir özelliği bulaşıcı olmalarıdır. Dünyanın herhangi bir yerindeki büyük çaplı bir kriz diğer ülkelere de bulaşabilir. Bu durum işletmeler için de geçerlidir. Herhangi bir sektörde meydana gelen kriz diğer sektörleri, işletmeleri ve bunların ilişki içinde olduğu organizasyonları da etkileyecektir.

1.4.2. Finansal kriz türleri

Finansal krizler, hükümetlerin hatalı yönetiminden kaynaklanan makroekonomik politikaların sebep olduğu krizler, finansal panik krizleri, köpük patlaması, ahlaki tehlike krizleri ve düzensiz çalışma şeklinde tanımlanmıştır (Radelet ve Sachs, 1998: 107-109). Her ne kadar finansal krizlerin meydana geliş süreci ve etkileri farklı olsa da kendi içinde ortak özellikleri de vardır. Finansal krizler ülkelerin ekonomisine dolayısıyla işletmelere zarar verecek, finansal krizin verdiği hasarı giderme maliyetleri artacaktır. Finansal krizlerin literatürde çeşitli gruplara ayrıldığı görülmektedir. Feldstein (1999: 6-13), finansal krizleri aşağıdaki gibi dörde ayırmıştır:

- Cari hesap krizleri
- Bilanço krizleri
- Banka krizleri
- Bulaşma krizleri

Sachs (1996) çalışmasında önemli üç finansal krize odaklanmıştır. Bu krizler; mali kriz, döviz krizi ve banka krizleri şeklindedir. Genel olarak krizler Şekil 1.2'de görüldüğü üzere; para, bankacılık, dış borç ve sistematik krizler şeklinde ayırma tabi tutulmaktadır.



Şekil 1.2. Finansal Krizlerin Sınıflandırılması (Delice, 2003: 63)

1.4.3. Krizler ve işletme başarısızlığı

Kriz, riskin ve belirsizliğin etki düzeyidir. İşletmeler açısından kriz, sonucu tehlike doğurabilen, işletmenin hedef, plan ve stratejilerini tehdit eden, hemen tepki gösterilmesi gereken, sıkıntı yaratan bir durumdur (Aydın vd., 2017: 328). İşletmeler varlığını devam ettirebilmesi, hedef ve amaçlarına ulaşması için finansal yapılarını güçlü yapılandırmalıdır. Globalleşen ve gelişen ekonomilerdeki makroekonomik faktörler işletmeleri finansal krizlere sürüklemektedirler. Finansal krizler işletmeleri iflasa götürecek kadar bir başarısızlığın içine atmaktadır (Usta, 2014: 189).

İşletmelerin başarısızlığı bir ya da birçok faktörün bir araya gelmesi ile bir sonuç oluştururken kriz, başarısızlığa neden olabilecek faktörlerden sadece birisidir. Kriz ve başarısızlık kavramları karıştırılabilmektedir. Bu sebeptendir ki işletmeler açısından kriz kavramının tanımlanması gerekmektedir. Aynı zamanda etkili bir risk yönetim politikaları ile negatif görünen olayların fırsatlara dönüştürülebilecek olmasıdır. İşletmeler açısından krizin temel özellikleri aşağıdaki gibi sıralanabilir (Aydın vd., 2017: 328):

- Kriz oluşma durumunun öngörülememesi,
- Krizi öngörme ve önleme mekanizmalarının yetersiz kalması,
- İşletmelerin amaç ve varlığını tehdit etmesi,
- Krizler aniden gelişebildiği için üstesinden gelinmesi için atılması gereken adımların kararlaştırılması konusunda yeterli zamanın bulunmaması,
- Kriz durumuna hemen tepki verilmesini gerektirmesi,
- Yönetim kademesine sıkıntı yaratması,
- Karar alıcılara sıkıntı yaratması,
- Korku, panik ve endişeye neden olması,
- Yetkiyi merkezileştirmesi.

Genelde krizler önceden sinyaller vermektedirler. İşletmelerdeki finansal yöneticiler krizlerin nasıl doğduğunu, etkilerini, kriz yönetimini, krizle nasıl baş edebileceğini bilmelidirler. Risk ve belirsizlik kriz dönemlerinde artar. Kriz yönetim politikası olmayan, etkili bir yönetim sergilemeyen, iyi bir plan yapamayan ve krizi fırsata çeviremeyen şirketler başarısız olabilmektedirler. Krizi yönetemeyen işletmeler piyasadaki pozisyonlarını kaybedebilmektedir. Özellikle borç oranı yüksek işletmeler daha fazla sıkıntı yaşamaktadır. Kriz öncesi küçülen ve borç oranını düşüren, öz sermayesi ağırlıklı hale gelen işletmeler daha az etkilenmektedir (Okka, 2015: 1060). Borç oranı yüksek işletmeler finansal sıkıntılı hale gelecek ve sonu iflasla sonuçlanabilecek bir finansal sıkıntı maliyeti de (iflas maliyetleri) ortaya çıkacaktır. Finansal sıkıntı durumuna düşen ve borçların ödenememesi durumunda aşağıdaki sorunlarla karşılaşılabilir (Ercan ve Ban, 2008: 238):

- Firma borçlarından doğan adli davalar, varlıkların nakde çevrilmesini engelleyerek sürecin uzaması varlıkların fiziksel olarak zarar görmesine neden olabilmektedir (Direk Maliyet).
- Avukat ücretleri, mahkeme masrafları ve yönetim giderleri firmanın değerinin azalmasına veya yok olmasına neden olabilmektedir (Direk Maliyet).
- Firmanın iflas etmesi durumunda işlerini kaybedeceklerini gören yöneticiler, firmanın finansal sıkıntılı dönemini uzatmaya çalışabileceklerdir. Bu süreç içinde firmanın makine ve teçhizatları değerinden çok aşağı fiyatlara satılabilmektedir (Dolaylı Maliyet).
- Firmanın uzun vadeli pazardaki durumu göz ardı edilerek maliyetleri düşürmek için ürün kalitesinden ödün verebilmektedir (Dolaylı Maliyet).
- Firmanın müşteri ve satıcıları da firmaya karşı olan davranışlarını değiştirebilirler (Dolaylı Maliyet).
- Firmanın cari değeri azalabilecek ve sermaye maliyeti artacaktır.
- Sıkıntılı dönemde firmanın hissedarları ile yöneticileri arasında bir çıkar çatışmaları meydana gelebilir ve bu çatışmalarından kaynaklı temsil maliyeti ortaya çıkacaktır.

1.4.4. Kriz dönemlerinde maliyetlerin mali başarısızlığa etkisi

Kriz dönemlerinde işletmelerin başarısızlığa uğramaması için maliyet faktörüne önem vermesi gerekmektedir. Maliyetler işletmelerin başarılı olmasında, rekabet etmede büyük bir etkidir. Üretilen mal veya hizmetlerin maliyetlerinin belirlenmesine ne kadar çok önem verilirse kriz dönemleri de daha az zararlarla atlatılabilir. Maliyetlerin sağlıklı hesaplanması neticesinde işletmelerin karı artarken hangi ürününün, hangi pazarda, hangi fiyatlarla satılması gerektiği konusunda işletme yönetimine yol gösterir. İşletme yönetiminin etkili bir planlama neticesinde sektörde rekabet avantajı elde edilir. Kaliteden ödün vermeden, maliyetlerini sektördeki diğer işletmeler ile aynı düzeye veya daha altına indiremeyen işletmeler faaliyetlerine devam etmesi mümkün değildir. Kriz dönemlerinde işletmeler alacaklarını tahsil edememe, hammadde ve kredi bulamama gibi durumlarla karşılaşır. Bu durumlar maliyetleri artırıcı faktörlerdir. Bu faktörlerin etkilerini

azaltmak için maliyetlerin azaltılması ve gereksiz maliyetlerin elimine edilmesi gerekmektedir (Karacan ve Savcı, 2011: 49).

1.5. FİNANSAL BAŞARISIZLIK İÇİN ALINABİLECEK ÖNLEMLER

Yükümlülüklerini yerine getirmek ve ticari işleyişini aksatmadan yürütmek isteyen işletmelerin birçoğu finansal sıkıntı ve dış finansman bulma ve kullanma hususunda kısır döngü içine girebilmektedir. Finansal sıkıntılar birçok sorunu beraberinde getirebilir. Bu sorunlar bazen işletmeyi iflasa kadar götürebilmektedir. Finansal sıkıntının erken tespiti ve bunlara karşı alınan önlemler, işletme ile ilişkisi olan işletme sahipleri, yatırım yapan yatırımcılar, kredi sağlayıcılar, çalışanlar, işletmenin elde ettiği kardan vergi alan devlet ve istihdam da meydana gelen artış ile oluşacak refah ile toplum için oldukça önemli bir durumdur (Ağırman, 2018: 404).

Küreselleşme ve teknolojik gelişmeler ile birlikte finansal sınırların ortadan kalkması, işletmeleri belirsizliğe doğru itmiş, belirsizlik ortamında doğru karar alamayan işletmeler finansal başarısızlık sürecini yaşamak zorunda kalmışlardır (Akkaya vd., 2009: 189).

Her işletmenin yapısı ve faaliyet gösterdiği sektör farklı olabileceğinden finansal sıkıntı ile karşılaştıklarında etkilenme seviyeleri ve sıkıntı biçimleri de farklı olacaktır. İşletme finansal sıkıntıya girmiş ya da yaklaşan finansal sıkıntı belirtileri teşhis edilebiliyorsa, zaman kaybetmeden bazı önlemler almak gerekmektedir. Bu önlemlerin alınamaması durumunda finansal başarısızlık kaçınılmaz olacaktır. Sıkıntı, işletme yönetim kademesinin gereken önlemleri stratejik bir plan dahilinde uygulayıp tekrar sektöründe yaşamını sürdürmesi ile sonuçlanmalıdır. Bu olay bir hastanın iyileşmesi için geçen sürece benzemektedir. Finansal sorunlar yaşayan işletmenin hastalığı teşhis edildikten sonra öncelikli olarak, borçlar nedeniyle ortaya çıkan faiz giderlerini durdurmak gerekmektedir. Nasıl ki bir insanın hayati damarından akan kan durdurulamazsa hayati tehlike kaçınılmaz olacak ise, işletmelerinde borç faizleri aynı etkiyi yapıp işletmeyi iflasa kadar sürükleyebilir (Okka, 2015: 1063).

Finansal yapısı bozulmuş, borç ödeme gücü zayıflamış, yükümlülüklerini yerine getirmede zorlanan bir işletme, varlığını sürdürebilmesi için aşağıdaki önlemlere başvurabilmektedir (Akgüç, 1998: 949):

- Borçların vadesini uzatmak,
- Borçları konsolide etmek veya röfinansman,
- Alacaklıların sulh yolu ile alacaklarının bir bölümünden vazgeçmeleri,
- İşletmenin, alacaklıların temsilcilerinden oluşan bir komite tarafından yönetilmesi,
- İşletmenin sermaye yapısının yeniden düzenlenmesi ve sermaye yapısının güçlendirilmesi,
- Varlıkların yeniden değerlendirilmesi,
- Maddi duran varlıkların satılarak, uzun süreli olarak kiralanması,
- Mali duran varlıkların kısmen veya tümüyle paraya çevrilmesi,
- Borçların menkul değer haline dönüştürülmesi,
- Konkordato önerilmesi,
- İşletmenin yasal statüsünü değiştirmesi,
- İşletmenin diğer bir işletme ile birleşmesi veya katılması,
- Bazı işletmelerin tamamen veya kısmen satılması,
- İşletmenin tasfiyesi.

Bu çalışmada işletmelerin finansal başarısızlığı önlemek için başvuracağı yöntemler; yeniden yapılandırma (reorganization), sermaye yapısının yeniden düzenlenmesi (recapitalization) ve tasfiye (liquidation) olarak üç ana başlıkta toplanmıştır. Tasfiye, alınan tüm önlem ve uygulamalara rağmen işletmenin varlığını devam ettirememesi durumunda ortaya çıktığı için ayrı bir başlık altında incelenmektedir. Finansal başarısızlığı önlemede uygulanan tüm metot ve uygulamalardaki amaç işletmenin varlığını sona erdirmek yani tasfiye değil işletmenin hayatını devam ettirmesini sağlamaktır (Salur, 2015: 19).

1.5.1. Yeniden yapılanma (Reorganization)

Günümüzde dünyada ve Türkiye’de hukuk sistemindeki ve mali piyasalardaki büyük değişim ile birlikte finansal sıkıntının da biçim ve şekli

değişmiştir (Wruck, 1990: 419). Yirmi yıl öncesi ile şimdiki zaman dilimindeki mali sıkıntıların biçim ve etki düzeyi aynı değildir. Dünyanın globalleşmesi, hukuk sisteminde yapılan değişiklikler ve hızlı bir şekilde büyüyen teknolojik devrim işletmeleri farklı etkilemeye başlamıştır. İşletmeler bu değişimlerin getireceği sıkıntıya her zaman değişik metotlarla hazır olmalıdırlar. İşletmeler herhangi bir finansal sıkıntı ile karşılaşmak istemiyorlarsa sürekli gelişmek zorundadır. Hiç gelişmeyen, sabit işletmeler gerçekte gerileyen ve finansal sıkıntı ile karşılaşmaya daha yakın yapıdaki işletmelerdir. Değişen yeni koşullara işletmeyi adapte etmek gerekmektedir. İşletme büyük atılım ve girişimler yapmak istiyorsa finansal yapısında köklü değişiklikler yapmalıdır (Sabuncuoğlu ve Tokol, 2009: 211). Bir işletmenin sermaye yapısını kökten değiştirme süreci, yeniden yapılanma şeklinde adlandırılmaktadır. Yeniden yapılanma, sektörde rekabeti desteklerken diğer yandan da hisse senedinin piyasa değerini artırır. Yeniden yapılanma stratejisi olarak küçülme stratejisi benimsenmişse yatırımlar azalacak ve dolayısıyla istihdam azalacaktır. İşletmeler için ekonomik anlamda yapı, belirli bir sürecin temel değişkenleri arasındaki belirli ve durağan ilişki üzerine odaklanmaktadır. İşletmelerde finansal yapı ise daha dinamik bir etkileşim içinde olan sermaye hareketlerini açıklamaktadır (C. Akkaya ve Tükenmez, 2007: 179).

Finansal yapının güçlenmesi ya da finansal sıkıntının çözümü için yeniden yapılanmaya gidilirken tercih edilecek süreç önemlidir. Finansal anlamda sıkıntıda ve mali yapısı sorunlu bir işletmede yeni bir sürecin denenmesi sürecin uzamasına dolayısıyla yeni maliyetlerin ortaya çıkmasına yol açacaktır. Özel olarak denenilen bir yeniden yapılanma şekli, eğer hatalı bir seçim ise finansal sıkıntıya yol açacak ve getireceği maliyet katlanarak artacaktır. Sıkıntı içerisine düşen ve finansal başarısızlığa uğramamak isteyen işletmelerin özel yapılandırma süreçleri ya da iflas yasaları çerçevesinde yeniden yapılandırmayı tercih etmelerinde etkili olan faktörlerin belirlenmesi finans literatüründe oldukça araştırılan konulardan biri haline gelmiştir (Sayılğan ve Coşkun, 2009: 147). Bir işletme mali sıkıntıda ise veya sıkıntılı duruma geçme pozisyonundaysa birkaç metotla çıkış yolu bulabilir. Bunların biri gönüllü olarak mali yapının yeniden yapılandırılmasıdır. Diğer alternatif yol ise iflas mahkemesi koruması altında faaliyetlerini ve mali taleplerin yeniden yapılandırılmasıdır (Clark ve Ofek, 1994: 541).

Reorganizasyon sürecinde alınabilecek önlemler şöyle sıralanabilir; borçların vadesinin uzatılması, alacaklıların alacaklarının bir kısmından vazgeçmesi, işletmenin alacaklıların temsilcilerinden oluşan bir komite tarafından yönetilmesi ve son olarak konkordato önerilmesi şeklinde sıralanabilir (Salur, 2015: 21).

1.5.1.1. Borçların vadesinin uzatımı

İşletmelerin yaptıkları ticari ilişkiler sırasında oluşan senetli ve senetsiz borçlar ticari kredi olarak tanımlanır. Müşterilerine mal satışlarında veya hizmet sunumlarında belli vade tanıyan işletmeler ticari alacaklara yatırım yapan işletmelerdir. Müşterilerine kredi tanıyan işletme de ticari kredi sağlayıcı işletme olarak tanımlanır. Kısacası vade tanıyan işletme satıcı, vade tanınan işletme ise alıcı rolündedir (Karaca ve Alsu, 2017: 147).

Finansal sıkıntı ile karşılaşan işletmeler öncelikle alacaklılar ile anlaşmaya çalışmaktadırlar. Sıkıntıdan kurtulmak için uygulanan yöntemler arasından en hızlı, düşük maliyetli ve işletmelerin piyasa değerine daha az oranda olumsuz etki yaratan yöntem anlaşma yöntemidir. İşletmeler borçlarının vadelerini gelecek nakit akışlarını da dikkate alarak, alacaklılar ile yeni ödeme planlarına bağlayarak içinde buldukları likidite sorununu aşmaya çalışırlar. Borçlu işletmenin kısa bir zaman dilimi içinde sorunu çözebileceğine güvenen alacaklılar anlaşma yöntemine yanaşabilir aksi takdirde alacaklılar anlaşma yöntemine yanaşmayacaktır. Alacaklılar, anlaşmayı kabul ederlerse alacaklarını gecikmeli tahsil edeceklerinin farkındadırlar (Özkanlı, 2011: 32). Sermaye analizi özellikle kriz dönemlerinde borçlu firmaların yaşamlarını sürdürmeleri açısından oldukça önemlidir. Sermayesi güçlü bir işletmenin borçlarını ödemekte sorun yaşama olasılığı diğerlerine kıyasla daha düşüktür (Dayı, 2015: 262). Bu analiz yöntemiyle alacaklılar, borçlu işletmenin borcunu ödeyememe durumu hakkında öngörude bulunabilmektedirler.

İşletmeler içinde buldukları şartlar nedeniyle geçici bir süre mali sıkıntı içine düşebilirler. İşletmenin temelde güçlü olmasına karşın, geçici nedenlerle yükümlülüklerini yerine getirememe durumu da olabilmektedir. Bu tip durumlarda alacaklılar açısından işletmenin tasfiyesine ya da iflasına neden olabilecek yasal yollara başvurmaktansa, alacakların vade süresini uzatmak daha mantıklı bir yöntemdir. Çünkü işletmenin mali sıkıntısı geçicidir ve işletme bu sıkıntıyı

atlabilecek güce sahiptir. Alacaklıların yasal yollara başvurmaları durumunda, oldukça zaman alan formalite ve giderlerin yanında, işletmenin tasfiye edilmesi sonucunda meydana gelecek değer kayıpları nedeniyle alacaklıların tüm haklarını tamamen elde etmeleri güç olacaktır. İşletmenin iflas veya tasfiye yöntemlerinin devreye sokulmasındansa, işletmenin varlığının devam ettirilmesinin sağlanması alacaklıların da faydasındadır. Alacaklıların bir kısmının borcun vadesinin uzatılması yöntemine taraf olmaması ve sadece az sayıda alacaklı ile anlaşma yoluna gidilmesi, istenen sonucu doğurmayacağı gibi, bu alacaklı veya alacaklıları, haklarını alma konusunda daha sıkıntılı duruma düşürebilir. Hiçbir alacaklı alacağının tahsisi konusunda sıkıntılı duruma düşmek istemez. Alacaklıların kendi aralarında görüş birliğine varıp, kendi mali çıkarlarını da gözeterek, sıkıntı içine düşmüş işletmeye bir ödeme planı sunması veya kendi aralarında borçlu işletme ile muhatap olacak bir komite oluşturması ve bu komitenin gerekli önlem, takip ve kontrollerin sağlanmasını yürütmesi ile borçların tahsisi daha hızlı olabilmektedir (Akgüç, 1998: 950).

1.5.1.2. Alacaklıların alacaklarının bir kısmından vazgeçmesi

Başarısız işletmelerin mali yapılarının güçlenmesi ve sağlamlaşması için alacaklılar alacaklarının bir bölümünden vazgeçebilmektedirler. Böylece finansal sıkıntı içindeki işletmenin tasfiye edilmesi durumunda ortaya çıkacak olan tasfiye maliyetleri elimine edilerek işletmenin yeniden faaliyet göstermesi sağlanır. Alacaklıların alacaklarının bir kısmından vazgeçmesi için şu üç koşulun varlığı gerekir (Berk, 2015: 616):

- İşletmenin varlıklarını kendi kişisel çıkarları uğruna kullanmayacak karakterde ve amacın sadece işletmenin finansal yapısının güçlendirilmesi amacına sahip olunması.
- Borçlu işletmenin gelecekte yükümlüklerini karşılama yeteneği kazanma beklentisi.

- Ekonomik koşulların borçlu işletmenin gelecekte başarılı olmasını destekler nitelikte sinyal vermesi.

1.5.1.3. İşletmenin alacaklıların temsilcilerinden oluşan bir komite tarafından yönetilmesi

Alacaklılar, finansal sıkıntı içinde olup mali yükümlülüklerini yerine getiremeyen işletmelerin, yönetimlerinden memnun olmama durumunda, yönetimi devralmak koşulu ile işletmeye yardımda bulunmayı isteyebilmektedir. Bu durumda, borçlu işletme ile alacaklı işletmeler, alacaklıların temsilcilerinden oluşan bir komite tarafından işletmenin yönetimi ve alacakların yönetimi konusunda anlaşabilmektedir. Bu komite işletmenin mali yapısı ve durumu iyileşmeye gittiğinde ve neticesinde finansal durum düzeldiğinde yönetimi yeniden devredecektir. Bu süreç içerisinde işletmenin üçüncü şahıslara karşı olan yükümlülükleri devam etmektedir (Uzun, 2005: 166).

Finansal yapılandırma eylemlerinin tümünde mali sıkıntıda olan işletmeye olan güven faktörü ön plandadır. Finansal sıkıntıda olan işletmenin bu süreci atlatması yönetim kademesinin atacağı adımlara da bağlıdır. Atılacak bu adımların alacaklılar tarafından uygun görülmesi gerekmektedir. Alacaklılar tarafında finansal sıkıntı içinde olan işletmelerin yönetim kademesinin bu sıkıntılı dönemi atlatacak kabiliyete sahip olmadığı inancı hâkimse yeniden yapılanma sürecinde rol almak istemeyebilirler. Bu durumda alacaklı işletmeler oluşturacakları bir komite ile sıkıntılı işletmenin yönetim kademesini devralmaktadır. Mevcut yönetimin yeterli altyapı, beceri, donanım ve kabiliyetinin olamaması sebebiyle oluşturulan komite işletmeyi ivedi bir şekilde yönetim yoluna girer. Bu yönetim süreci, sıkıntılı işletmenin mali durumunun düzelmesi ile son bulur. Komite yönetimi tekrar işletme sahiplerine devreder. Tüm bu adımlara rağmen işletmenin sıkıntılı durumu atlatması mümkün görünmüyorsa komite işletmenin tasfiyesi için gerekli önlemleri alır (Salur, 2015: 23).

Bu konuyla ilgili olarak ülkemizde bazı yasal uygulamalar söz konusudur. 15 Ağustos 2018 tarihinde yürürlüğe giren Finansal Yeniden Yapılandırma ve Çerçeve Anlaşması gönüllülük esasına dayalı olup özetle aşağıdaki maddeleri içermektedir (Atalay, 2018):

- Finansal Yeniden Yapılandırma ve Çerçeve Anlaşması gönüllülük esasına dayalıdır
- Finansal Yeniden Yapılandırma ve Çerçeve Anlaşmasından yararlanabilecek borçluların, taraf bankalara 50 milyon TL den fazla borcu olmalıdır.
- Finansal Yeniden Yapılandırma ve Çerçeve Anlaşması, yargısal bir müracaat ve denetim içermemektedir.
- Borçlu şirket ile anlaşmayan alacaklıların icra takiplerini engelleyecek bir süreç yoktur.
- Bu anlaşma kapsamına alınacak şirketlerin konkordato talep etmemiş olmaları gerekmektedir.
- Finansal Yeniden Yapılandırma ve Çerçeve Anlaşması uygulama süresi 2 yıldır.
- Bankalar, borçlu şirketten, sermaye artırımı, yönetim değişikliği, halka açılma, iştirak ve varlık satışı, ortaklık yapısının değiştirilmesi, şirket hisseleri üzerinde alacaklı bankalar lehine rehin tesis edebilecektir.

1.5.1.4. Konkordato önerilmesi

Konkordato, iyiniyetli borçluların sektördeki yaşamlarının devam ettirmelerine yarayan, istihdam yapısının bozulmasının önüne geçen bir kurumdur (Erol, 2017). Konkordato, "*borçların yeniden yapılandırılması suretiyle iflasa tabi borçluların mali durumunun düzeltilerek iflastan kurtulmasını, diğer borçluların ise mali durumunun düzeltilmesini amaçlayan, alacaklıların da belirli bir tenzilatla veya vadede alacağına kavuşmasını sağlayan ve mahkemenin tasdiğiyle taraflar açısından bağlayıcı hale gelen bir anlaşma*" olarak tanımlanır (Yavuz, 2018: 161).

İflas talebinde bulunabilecek her alacaklı, gerekçeli bir dilekçeyle, borçlu hakkında konkordato işlemlerinin başlatılmasını isteyebilmektedir. Alacaklıların konkordato talebi üzerine mahkeme, gerekli incelemelerin ardından geçici mühlet kararı verecek ve borçlunun mevcut malvarlığının korunması için tedbirler alacaktır. Geçici mühlet, kesin mühletin sonuçlarını oluşturacaktır. Mahkeme geçici mühlet kararını ticaret sicili gazetesinde ve Basın İlan Kurumunun resmi ilan portalında ilan edecektir. Bununla beraber tapu müdürlüklerine, ticaret sicili müdürlüğüne, vergi

dairesine, gümrük ve posta idarelerine, Türkiye Bankalar Birliğine, Türkiye Katılım Bankaları Birliğine, mahalli ticaret odalarına, sanayi odalarına, taşınır kıymet borsalarına, Sermaye Piyasası Kuruluna ve diğer ilgili yerlere bildirilmektedir (İİK,1932, m.288). Mahkeme, kesin mühlet hakkındaki kararını, geçici mühlet içinde verir. Konkordatonun başarıya ulaşmasının mümkün olduğunun anlaşılması halinde borçluya bir yıllık kesin mühlet verilir (İİK,1932,m.289).

67 maddeden oluşan ve 28.02.2018 tarihinde kabul edilerek 15.03.2018 tarih ve 30361 sayılı Resmi Gazetede yayınlanarak yürürlüğe giren yasa değişikliğinin genel gerekçesinde, ülkemizde 2003 yılından bu yana uygulanan iflasın ertelenmesi kurumu, ihdas amacının gerçekleştirilmesi konusunda isteneni veremediği gerekçesiyle 15.07.2016 tarihinde kabul edilen 6728 sayılı kanunla revize edilmiştir. İflasın ertelenmesinde, alacaklıların herhangi bir şekilde etkisinin olmaması, sürecin borçlu ve mahkeme arasında yürütülmesi ve yaşanan yargılama sorunları sonucunda iflasın ertelenmesi kurumunun tamamıyla yürürlükten kaldırılması kararlaştırılmıştır. Yürürlükten kaldırılan kurumun yerine alacaklılar ile borçlunun anlaşmalarının sağlanması ve bu anlaşmanın mahkemece tasdik edilmesi gerekmektedir. Konkordato kurumunun daha etkili ve verimli bir şekilde yürütülmesi işletmelerin ticari ve sosyal hayat bakımından bir ihtiyaç olarak görülmesi üzerine kanun düzenlenmesi yapılmıştır (Aslanoğlu vd., 2017: 66).

1.5.2. Sermaye yapısının yeniden düzenlenmesi

İşletmelerin sermaye yapılarının değiştirilmesi yoluyla işletmelerin başarısızlığı çözüme kavuşturulabilir. İşletmenin borçlarını ödemek için değişik kaynaklardan uygun şartlarla borç para bulması gerekir. İşletmeye yeni ortakların alınması ile sermaye yapısının güçlenmesi sağlanabilir. Öz sermaye sahiplerinin tahville değişim yapmaları sağlanarak pay başına kazanç artırılarak, sermaye yapısı değiştirilebilmektedir (Ceylan ve Korkmaz, 2015: 377). Yapılanmadaki asıl amaç işletmenin tasfiyesinden ziyade, çeşitli yöntemlerle hayatlarına devam ettirilmesidir. Bu durum tarafların çıkarına olabilecektir. Sermaye yapısının yeniden yapılanmasında aşağıdaki önlemler alınabilir (Akgüç, 1998: 951):

- Borçlara karşılık sermayeye iştirak payı verilmesi

- Tahvillere karşılık pay senedi verilmesi
- İşletmeye yeni ortaklar alınması
- Sabit faiz yükü getiren tahvillerin kara iştirakli tahvillerle değiştirilmesi
- Tahvil faizlerinin indirilmesi
- İmtiyazlı pay senetleri yerine adi pay senedi verilmesi
- Anonim şirketlerde pay senetlerinin nominal değerlerinin düşürülmesi

1.5.3. İşletmenin tasfiyesi

Mali yapısı bozulmuş bir işletme için tüm operasyonlara, uğraşılara rağmen, yapısında etkili bir düzelme olmadığında son çare olarak tasfiyeye gider. Tasfiyenin sözlük anlamı, temizleme, hesabı kapatmaktır. Tasfiye hali, faaliyetine son veren şirketin ve işletmelerin tüm hesaplarının kapatılmasıdır (Türk, 2016). Resmi tasfiyeden önce borçlu ve alacaklıların anlaşması ile gayri resmi tasfiye süreci ile alacaklılar resmi iflas tasfiyesinden daha fazla miktar varlık elde edebilirler (Ehrhardt ve Brigham, 2011: 874). Bu gayri resmi tasfiye, eğer borçlu firma çok büyük ve karmaşık bir yapı içinde değilse uygulanacaktır (Brigham ve Daves, 2007: 904).

Tasfiye sürecine giren işletme için, işletmenin artık ölüsü canlı halinden daha değerli hale gelmiştir (Brigham ve Houston, 2007: 382). Borçlu işletme, alacaklıların alacakları ile ilgili bir anlaşmaya varamayıp, reorganizasyon sürecinde de bir ilerleme sağlanamaması nedeniyle işletmenin ani olarak sona ermesi kaçınılmazdır. İşletme, faaliyetlerinin sona ermesi ile tasfiye sürecine girer ve tasfiye işlemleri bitene kadar varlığını devam ettirir. Özetle tasfiye; işletmenin varlıklarının paraya çevrilmesi, borçlarının ödenmesi ve borçların ödenmesinden sonra bir değer kalırsa bunun işletmenin sahip, ortaklarına veya hissedarlarına dağıtılması işlemidir (Uzun, 2005: 167). Hissedarların tasfiye sürecindeki stratejileri borcun büyüklüğüne bağlıdır. Likit olmayan bir varlık, borcun seviyesinden daha yüksek bir miktarda satılmaya çalışılır. Eğer bu başarılı olabilirse borç ödenebilir ve fark dağıtılabilir. Sahip olunan varlığı ya da varlıkları borcun daha altında satmanın bir anlamı yoktur. Çünkü böyle bir satış işletmeyi derhal temerrüde sokabilmektedir (Kelly ve LeRoy, 2007: 554).

Türk Ticaret Kanunu'na göre, tasfiye sürecine girmiş işletmelerin varlıkları açık artırma veya pazarlık yöntemiyle satılabilir. İşletmenin yasal statüsüne göre, ortaklarının veya genel kurulun kararı ile varlıkların toptan satılması da mümkündür. Gerekli yasal koşulların oluşması halinde alacaklılar hatta işletmenin kendisi tarafından iflasın talep edilmesi suretiyle de işletmenin varlığına son verilebilmektedir (Akgüç, 1998: 956).

1.6. FİNANSAL BAŞARISIZLIK TAHMİNİ

1.6.1. Finansal başarısızlığın tahmin edilmesinin önemi

Finansal başarısızlık, işletmelerin finansal yükümlülüklerini yerine getirememesi olarak tanımlanmıştır. Başarısızlık dünya çapında bir sorundur ve tüm ülke ekonomileri için başarısız işletmelerin sayısı önemlidir. Bu sayı dünyanın dört bir yanında bulunan işletmeleri etkileyebilir ve ülke ekonomilerinde etki bırakabilir (Rafique ve Al Mamun, 2015: 115).

Finansal sıkıntı içinde olan şirketlerin tahmin edilmesi finans alanında yapılan çalışmalar için de önemli bir yer tutmaktadır. Bundan sonra da finans literatüründe önemle üzerinde durulması gereken bir konudur ve önemini yıllar sonra bile sürdürme potansiyeline sahiptir (Kaygın vd., 2016: 148).

Finansal sıkıntı içindeki işletmelerin tahmin edilme başarısı ya da kabiliyeti, hem işletmeler için hem de potansiyel ve mevcut yatırımcılar için önemlidir. Buradaki tahmin başarısı finans yöneticileri ve borsa düzenleyicileri için de fazlasıyla önem arz etmektedir (Alifiah, 2014: 90). İşletmeleri finansal sıkıntı içine girmeden tahmin edip önlemler almak, işletmeleri yeniden sektördeki yaşamına döndürebilmektedir. Aksi takdirde bu durum işletmelerin tasfiyesine veya iflasına kadar gidebilmektedir (Zeytinoglu ve Akarim, 2013: 107).

İşletmelerin mali yapısının bozulup sıkıntı içine girmesinin ülkelerin finans ve ekonomileri açısından negatif sonuçları vardır. İşletmeler mali sıkıntı içine girmeleri ile birlikte bazı maliyetlerle karşılaşır. Bu maliyetler dolaylı ya da dolaysız olabilecektir. Mali başarısızlık nedeniyle olumsuz etkilenen üretim ve istihdam, ülkelerin sosyo-ekonomik dinamikleri üzerinde ciddi sıkıntılar oluşturmaktadır. Bu sebeple finansal başarısızlığın önceden tahmin edilmesi

ülkelerin kaynaklarının verimli kullanılması açısından ve ülkelerin hem ekonomik hem de istikrarı açısından önemlidir (Akbulut ve Rençber, 2016: 781).

Finansal başarısızlığın öngörülmesi ile fayda sağlayacak olanlar; işletme yöneticileri, yatırımcılar, kredi verenler, devlet, düzenleyici kuruluşlar, iş ve işçi kuruluşları şeklinde sıralanabilir (Salur, 2015: 29).

1.6.1.1. İşletme yöneticileri açısından önemi

Akgüç (1998), Ceylan ve Korkmaz (2015), Gökçe ve Şahin (2003) literatürde yapılan çalışmaların birçoğunda başarısızlığın ana faktörünün işletme yönetimi olduğu belirtmişlerdir. Başarısızlığın önceden tahmin edilmesinin faydası en fazla işletme yönetimine olmaktadır. İşletme yöneticileri finansal başarısızlık tahmin modellerini kullanarak işletmelerinin olası bir mali sıkıntı içine girmeden gerekli önlemlerini alarak sektördeki faaliyetlerine, rekabet gücünü artırarak devam edebilmektedirler (Torun 2007: 16).

Finansal başarısızlığın önceden doğru tahmin edilmesi işletme yöneticilerine işletmelerinin geleceği ile ilgili çok önemli bilgiler vermektedir. Yöneticiler finansal başarısızlık tahmin modellerini kullanarak yatırımlarını, satış hacimlerini, yeni projelerini, rekabet stratejileri gibi faaliyetlerini daha etkili planlayabilmektedirler. Kullanılan modeller işletmelerin başarısızlığını önleyebileceği gibi aynı zamanda fon bulma, yeni iş ortaklıkları kurma ve faaliyet alanı değiştirme gibi konularda da yöneticilere yol göstermektedir. İşletmeler mali başarısızlık tahmin modellerini kendi işletmeleri üzerinde uygulayabilecekleri gibi aynı zamanda faaliyet alanında işbirliği içinde buldukları işletmelere, müşterilere, tedarikçilerine ve satıcılara da uygulayarak onlarla olan ilişkilerini de yeniden şekillendirebilmektedirler. Modeli uygulayan işletme, ticari ilişki içinde olduğu paydaşlarının mali yapısının durumunu önceden doğru tahmin edebilirse sonrasında yaşanacak tehlike veya sorunu daha kolay engelleyebilmektedirler (Kılıç 2011: 23).

1.6.1.2. Yatırımcılar açısından önemi

Yatırımcıların şirket başarısızlığından etkilenmemesi ve başarısızlığın erken tespitinin sağlanması için sağlam modellerin geliştirilmesinin önemi her geçen gün daha fazla artmaktadır (Horta ve Camanho, 2013: 6253). Amerika Birleşik

Devletin Texas merkezli dev şirketi Enron'un 2001 yılında iflas etmesi ABD'de büyük bir tartışmaya neden olmuştur. Bu şirketin iflas etmesinden önce kredi derecelendirme kuruluşları, analistler, denetçiler ve devlet kanalından herhangi bir uyarının yapılmamış olması yatırımcılar tarafından tepki ile karşılanmıştır. Yatırımcılar özellikle erken uyarı sisteminin neden çalışmadığını şiddetle sorgulamışlardır (Arthtur vd., 2005: 6).

Başarısız işletmeye yatırım yapan, kredi veren veya ticari ilişki içinde bulunan tüm paydaşlar eğer bu sıkıntıyı önceden tahmin edebilirlerse yatırımlarını yeniden şekillendirebilirler. Erken tahmin ile yatırımcı başarısız işletmedeki hisselerini zarara uğramadan satabilmekte, portföyünü güncelleyebilmektedirler. Tahmin modellemeleri ile yapılacak analiz ile işletmenin mali yapısının güçlü ve başarısızlığının geçici olduğuna inanılırsa kazanma stratejisi oluşturmak da mümkün hale gelir. Yatırımcı sıkıntı içinde olan işletmenin hisselerini düşük fiyattan alarak sıkıntılı dönemin atlatılması ile yükselecek hisse fiyatları ile kar elde etme fırsatını kazanır Yani doğru tahmin modellemesi ile bu durum fırsata dönüşür (Kılıç 2011: 24).

Yatırımcılar tarafından finansal başarısızlığın doğru tahmin edilmesi ile satın alma ve satma kararlarındaki başarı artar. Her geçen gün globalleşen sermaye piyasaları ile çeşitli yatırım alanları oluşmaktadır. Kişinin her yatırım aracını değerlendirme ve analiz etme bilgisi olamayabilir. Bireysel yatırımcının finansal bilgi eksikliğine sahip ve deneyimsiz olması neticesinde fonların etkin bir şekilde yönetimi gerçekleştirememektedir. Bu durum bireysel yatırımcının yatırım kararlarında hatalı davranmasına ve beklenen getirisinin istenilen düzeyde olmamasına neden olmaktadır. Finansal başarısızlık tahmin modelleri yatırımcılara karar almalarında yardımcı olabileceği gibi, yatırımcıların finansal tecrübe eksikliği ile oluşabilecek hata payının azalmasını sağlar. Bu şekilde yatırımcılar doğru alanlara yatırım yapıp maksimum getiriye elde etme amacına ulaşabilirler. Bu amaca ulaşırken fonlar da rasyonel şekilde dağıtılır ve işletmeler sektörde rekabet avantajı elde edebilir (Akkoç, 2007: 29).

1.6.1.3. Devlet açısından önemi

Devletler, vergilendirmeyi doğru yapabilmek, denetim işlevini sürdürebilmek ve ekonomi politikaları ile stratejilerini geliştirebilmek için işletmelerin finansal tablolarını incelerler. Devletler, ulusal gelir kaynağı olan işletmelerin başarısı, mali yapısı ve gelecekteki pozisyonuyla ilgilidirler. İşletmelerin finansal başarısızlığının doğru tahmin edilmesiyle devletler, ülke ekonomisinin büyümesi ve gelişimi doğrultusunda daha etkin politikalar izleyebilirler. Bir ülkede konkordatoya başvuran ya da iflas eden işletme sayısının artması o ülkenin ekonomisinin iyiye gitmediğinin açık göstergesidir. Ülke yönetimi dışında yabancı ülkeler, kredi kuruluşları ve yabancı yatırımcılar da iflaslar ile ilgili verileri dikkatlice takip etmektedirler. Önceden öngörülebilir sıkıntılı durumlar iyileştirilebilirse, ülkelerin de ekonomik yapısı güçlenir. Aksi durumda başarısızlık sonucu gelecek iflaslar zincirleme etkisi yaparak, başarısız işletme ile ticari ilişki içinde olan paydaşları da iflasa sürükleyebilir (Çelik, 2009: 25).

Devletler giderlerinin büyük bir kısmını topladığı vergilerle karşılanmaktadır. Toplanan vergilerin düzenli olmasından dolayı vergi geliri devletin diğer gelirlerine göre daha istikrarlıdır. Bütçe açığının oluşmaması için bu istikrarın korunması ve vergi sağlanan kesimin sağlıklı bir şekilde büyütülmesi gerekmektedir. Devletlerin vergi gelirlerini arttırması, işlerlik kazanmış bir ekonomide mali anlamda sıkıntı yaşamayan işletmelerin varlığı ile mümkündür. İşletmelerin başarısızlığa uğramadan kar edebilecek bir faaliyet içinde olması, devletlerin uygulayacağı para ve maliye politikalarına bağlıdır. Devletin vergi artırımını gibi bir politikası olursa bunun sonucunda devlet gelirlerini arttırabilir ancak bazı işletmeler bu vergi artırımını neticesinde sıkıntıya girip faaliyetlerini sonlandırabilir. İflas eden işletmelerin sayısı artıkça vergi gelirlerinde de azalmaya neden olur. Bu durumda devletin yaptığı mali plan ve program sekteye uğrar. Devletler etkili ve doğru finansal başarısızlık tahmin modellerini kullanarak bu durumu lehlerine çevirebilirler. Eğer devletin sorumlu organları ileriki süreci tahmin edemeyip işletmelerin iflaslarını engelleyemezse, büyük bir işsizlik sorunu ile muhatap olur. Devlet tüm bu sıkıntı ve problemler oluşmadan etkin, doğru ve güvenilir tahmin modelleri kullanarak bu sıkıntılı süreci tersine çevirip güçlü çıkabilir (Akkoç, 2007: 29).

1.6.1.4. İş ve işçi kuruluşları açısından önemi

İşletmelerde önemli faktör olan sermayenin varlığı ile değer kazanan emek, üretim öğelerinin başında yer almaktadır. İş ve işçi kuruluşlarının gelecekte var olması ve işlerine devam edebilmeleri için finansal başarısızlığın tahmin edilmesi önemlidir. İşçilerin bağlı oldukları kuruluşlar, işletmelerin finansal tablolarını yorumlayarak ücret artışı talebinde bulunmaktadırlar. Ücret artışı dışında kader birliği içinde buldukları işletmelerin geleceğindeki finansal durumunun tahmin edilebilmesi iş ve işçi kuruluşlarının gelecekteki açısından büyük önem taşımaktadır. Gelecekte iflas ihtimali olan bir işletmede gerekli önlemlerin alınıp işletmenin hayatına devam etmesi, işçi ücretlerinin artışından daha önem arz etmektedir (Keskin, 2002: 30).

Hizmet odaklı veya üretim odaklı faaliyet gösteren işletmelerin paydaşlarından olan, işçi ve işçinin haklarını takip eden işçi kuruluşlarının, ekonomik sistem içinde önemi büyüktür. Ülkelerin ekonomik yapısının düzgün işlemesi için mutlak surette işletmelerde çalışan işçilerin sıkıntıya düşmeden işlerine devam etmeleri gerekmektedir. Çalışan paydaşların var olması ve işlerine devam etmesi için bağlı oldukları ve ekonomik sistemin çarklarının bir tanesi olan işletmelerin sağlıklı bir hayat sürmeleri önemlidir. Gelecekte finansal başarısızlığa uğrayacak bir işletme için daha önceden herhangi bir öngöründe bulunamamak, işçi ve işletmeyi aniden sıkıntılı bir sürece itecektir. İşletme ile birlikte sıkıntıya girecek olan işçiler ülkenin sosyal yapısını bozarak istihdam problemi oluştururlar.

1.6.1.5. Bağımsız denetçiler açısından önemi

Finansal sıkıntı içinde olan işletmelere ait finansal raporlarda daha fazla hata olabileceği ve bu hataların da makyajla gizlenme ihtimali mümkündür. Bunun anlamı daha yüksek kontrol ve bulgu riski demektir. Bağımsız denetçiler işletmelerin finansal durumunu bir çok kriteri baz alarak incelemektedirler (Yıldız, 1999: 35). Bağımsız denetçiler işletmelerin finansal raporlarının gerçekliğini denetleyen kişi ya da kurumlardır. Bu denetlenen finansal tablolardan; ortaklar, yöneticiler, yatırım ve kredi sahipleri, işletmeye yatırım yapmayı düşünen potansiyel yatırımcılar ve devlet organları gibi çeşitli gruplar faydalanmaktadırlar. Bu sebeple birçok grubu ilgilendiren mali tabloların uygun formatta hazırlanması konusunda bağımsız denetçilere önemli sorumluluklar yüklenmiştir. Bağımsız denetçilerin inceledikleri işletmenin ileride finansal başarısızlığa düşeceği gibi bir görüş bildirme zorunluluğu

yoktur. Bağımsız denetçinin, hakkında olumlu görüş bildirdiği işletme başarısız olabileceği gibi, hakkında olumsuz görüş bildirdiği işletme ileride başarılı da olabilir. Bağımsız denetçilerin finansal başarısızlık konusunda kullanabilecekleri bir tahmin modeli, denetçinin denetim riski konusunda daha fazla bilgi edinmesini sağlar ve denetçilere müşterilerini seçme konusunda yardımcı olur. Denetçilerin kullanabileceği güvenli bir model, müşterilerinin ileride karşılaşılabileceği sorunlara çözüm getirir. Danışmalık hizmeti veren mali analistlerin ve dış denetçilerin kullanacakları etkin ve doğru öngörü modelleri, işletmeleri iflastan kurtarabileceği gibi iflastan kurtardıkları işletmelerin ekonomiye katkısı ile ayrıca ülkenin sosyo-ekonomik döngüsüne de katkı sağlayabilirler (Kılıç 2011: 24).

1.6.1.6. Düzenleyici kuruluşlar açısından önemi

Küreselleşme ile birlikte devletlerin ekonomi içindeki payının azaldığı görülmektedir. Yeni düzende devlet, ekonomi içinde bir oyuncu olarak değil oyun kurallarını belirleyen ve düzenleyen bir role geçmiştir. Devletin yürütmekte olduğu bu işleve “regülasyon” denilmektedir. Devletlerin elinde bulundurduğu “regülasyon” işlevi, kendilerine ait yasaları doğrultusunda merkezi otoriteden bağımsız olarak faaliyetlerini sürdüren ve tüzel kişiliğe sahip olan “düzenleyici ve denetleyici kuruluşlar” tarafından yerine getirilmektedir (İlman ve Tekeli, 2016: 23).

Ülkemizde de sigorta ve sermaye piyasaları gibi piyasaları düzenlemekle görevli kuruluşlar vardır. Bunlara, Kamu Gözetimi Muhasebe ve Denetim Standartları Kurumu (KGK), Türkiye Cumhuriyeti Merkez Bankası (TCMB), Kamu Gözetimi, Tasarruf Mevduatı Sigorta Fonu (TMSF), Bankacılık Düzenleme ve Denetleme Kurumu (BDDK), Sermaye Piyasası Kurulu (SPK) gibi kurumlar örnek olarak verilebilir. İş dünyası ve toplumun birçok kesimini etkileyen piyasalar düzenleyici kuruluşlar tarafından takip edilmektedir. Düzenleyici kuruluşlar, piyasaların dengesini bozacak, sıkıntıya sokacak ihtimal dahilindeki tüm hareketleri önceden tespit edilerek önlenmeye çalışmaktadırlar. Finansal başarısızlığı önceden öngörme başarısı, düzenleyici kuruluşların izleme ve kontrol yetkilerini artırıcı bir etki yapacağından bu kuruluşlar için yararlı olur (Salur, 2015: 32).

1.6.1.7. Kredi kurumları açısından önemi

Kredi veren kurumlar kredinin geri ödenip ödenemeyeceği konusuna her zaman önem vermişlerdir. İşi özellikle kredi vermek olan bankalar için bu durum daha önemlidir. Bankalar kredi vereceği işletmelerin risk durumunu değerlendirmeye alırlar. Çünkü bu durum kredi verenler için hayati önemlidir. Kredi kurumları fon verecekleri işletmelerin finansal başarısızlık risklerini önceden öngörüp ona göre fon aktaracakları işletmeleri seçmeleri bu kurumların daha güçlü olmasını sağlamaktadır. Yüksek tahmin başarısına sahip bir finansal başarısızlık modeli kullanarak, hangi işletmelere kredi olanağı sağlanabileceği, hangilerine sağlanamayacağı tespit edilebilir. Böylelikle henüz işin başındayken tehlike bertaraf edilebilir. Kredi kurumları uygun öngörü modellerini kullanarak daha az uzman istihdam ederek tasarruf sağlamış olurlar (Yıldız, 1999: 21).

Kredi veren kurumların başarısız olacak bir işletmeye kredi sağlamalarının fırsat maliyeti söz konusudur. En başta, verilen kredi, verimsiz bir şekilde değerlendirilmiş olacak, diğer taraftan bu kredinin başarılı olacak bir işletmeye kullandırılmaması durumunda gerçekleşecek üretimden de vazgeçilmiş olunmaktadır. Kıt olan kaynakların verimli değerlendirilmemesi ekonomik ve sosyal açıdan bir takım problemleri beraberinde getirmektedir (Akkoç, 2007: 26).

Özetle bu problemlerin meydana gelmeden öngörülmesi ile krediler doğru işletmelere aktarılır, böylelikle ülke ekonomisi başta olmak üzere bu durumdan dolaylı veya dolaysız etkilenen tüm paydaşların da refah seviyesi artar.

İKİNCİ BÖLÜM

FİNANSAL BAŞARISIZLIK TAHMİNİNDE KULLANILAN MODELLER

Bu bölümde finansal başarısızlığın önceden tahmin edilmesi için kullanılan istatistiki modeller ve yapay zekâ modelleri açıklanacaktır.

2.1. MATEMATİKSEL VE İSTATİSTİKSEL MODELLER

Finansal başarısızlığın tahmin edilmesinde istatistiksel metotların kullanımı daha çok 1960'ların sonlarına doğru başlamıştır (Suarez, 2004: 6). İstatistiksel modeller işletme başarısızlığını tahmin etmede en çok ve en yaygın kullanılan tekniklerdir. Bu tip modellerde klasik modelleme teknikleri kullanılmaktadır. Bu modeller oluşturulurken kullanılacak veriler şirketlerin finansal tablolarıdır. İstatistiksel modeller kullanılan değişken sayısına göre tek değişkenli istatistiki modeller ve çok değişkenli istatistiki modeller şeklinde ayrılmaktadır. Literatürde tek/çok değişkenli analiz yöntemleri kullanılarak finansal başarısızlık tahmini konusunda Tablo 2.1'de mevcut bazı çalışmalar yapılmıştır (Moharrampour vd., 2014: 624).

Tablo 2.1. Finansal Başarısızlık Konusunda Yapılan İstatistiki Modeller (Moharrampour vd., 2014)

	Tahmin Modeli	Yıl
1	The William Beaver	1966
2	Altman model	1968
3	D. Kane model	1972
4	Aspryngt model	1978
5	Ahlsvn model	1980
6	Toffler model	1983
7	Zmyjvsky model	1984
8	Falmr model	1984
9	Zavgyn model	1985
10	Chi-square model	1987
11	Grice model	1998
12	Fylsvvfr model	2002

Tablo 2.1’de gösterilen modeller kullanılan değişken sayıları ile farklılaşmaktadırlar. Örneğin Altman (1968) 22 finansal orandan 5 finansal oranı çalışmasına dahil ederken, D.kane (1972) 14 finansal oranı değişken olarak kullanmıştır. Tabloda yer alan çalışmalarda yazarlar işletmenin başarısızlığını önceden tahmin edebilecek en etkili finansal oranları kullanmışlardır.

2.1.1. Tek değişkenli istatistiksel modeller

Finansal anlamda başarısız işletmelerin tespitinde nesnel ölçütlere dayanan modeller genellikle işletmelerin mali oranlarını bağımsız değişken olarak kullanılırlar. Mali oranların kullanılması çalışmaya bazı avantajlar katması beklenmektedir. Mali oranların kullanılması ile işletme büyüklüğü ve risk sınıfı gibi modele dahil olmayan faktörler kontrol altına alınmakta, böylelikle bu faktörlerin sebep olabileceği sorunların azaltılması mümkün olmaktadır. Bu durumda farklı büyüklükteki ve farklı risk grubunda bulunan işletmelerin aynı örneklem dahilinde analizi yapılabilmektedir. Oranlara bağlı modeller, kullanılan modeldeki değişken sayısı bakımından tek ya da çok değişkenli olabilir. Modelde sadece mali oranının tek değişken olarak kullanıldığı modeller tek değişkenli ya da tek boyutlu modeller şeklinde adlandırılmaktadır. Tek değişkenli/tek boyutlu modellerin kullanılması uygulama kolaylığı açısından bazı üstünlükler gösterse de, tek değişkenli modellerin kullanılması ile çelişkili sonuçların ortaya çıkması, tek değişkenli modelde kullanılan oranın önemsiz çıkması, analiz edilen varlığın hem tüm özelliklerini hem de bu özellikler arasındaki ilişkiyi ölçmenin mümkün olmaması ve tek değişkenli modellerin tahmin etme gücünün düşük olması gibi durumların varlığı sebebiyle tek değişkenli modeller eleştirilmektedir (Aktaş vd., 2003: 4-7).

Tek değişkenli modeller bir dizi kısıtlayıcı varsayımlara dayanır. Özellikle tek değişkenli modelde firma başarısızlığını tahmin etmek için kullanılan bağımsız değişkenler (oranlar) ile bağımlı değişken arasında doğrusal bir ilişkinin olduğu varsayılmaktadır. Fakat bu varsayım uygulamada her zaman doğru olmayabilir. Bu durumda tek değişkenli analizin sonuçlarının şüpheli olması riski ortaya çıkar Beaver (1966) yaptığı çalışmada tek değişkenli modellerde kullanılan bir oranının firmayı başarısız sınıfına dahil ederken başka bir oran firmayı başarılı sınıfına dahil

edebileceği sonucuna ulaşmıştır. Bu duruma “ tutarsızlık problemi” denilmektedir (Altman, 1968). Tek değişkenli modelde tek bir oranın işletmenin doğrusal olmayan ve çok boyutlu statüsünü kapsamadaki problemi sıkıntıya sebep olabilmektedir. Tek değişkenli modelde tip 1 ve tip 2 hataların görece maliyetleri hesaba katılmamaktadır (Argyrou, 2006: 10-11).

2.1.2. Çok değişkenli istatistiksel modeller

Altman (1968) yaptığı çalışmada basit bir finansal oran ile işletmelerin karmaşık durumdaki finansal başarısızlığının önceden öngörülmesi ile ilgili yaptığı çalışmanın şüpheli ve yanıltıcı sonuçlar vermesi üzerine, sonraki dönemlerde finansal başarısızlığın tespiti için yapılan çalışmalarda birden fazla oranların kombinasyonlarından oluşan çoklu diskriminant analizi kullanılmıştır.

Tablo 2.2’de görüldüğü üzere, Altman (1968), Deakin (1972), Sinkey (1975), Altman, Haldeman, ve Narayanan (1977) oluşturdukları çok boyutlu modellerde finansal tablolardan elde edilmiş birden fazla oran kullanmışlardır.

Tablo 2.2. Çok Boyutlu Modellerde Kullanılan Oranlar (Scott, 1981)

Altman (1968)	FVÖK/TV, Satışlar/TV, HD/TB, DK/TV, ÇS/TV
Deakin (1972)	ÇS/TV, DV/KVY, TB/TV, LV/Satışlar, LV/TV, Nakit/TV, Nakit/Satışlar, DV/TV, Nakit/KVY, NG/TV, DV/Satışlar, Nakit Akışı/TB
Sinkey (1975)	Gelirin% 'Si Olarak Diğer Giderler, Gelirin% 'Si Olarak Krediler, FG/FGE, Krediler/Yedek Sermaye, Gelirin% 'Si Olarak Devlet Ve Yerel Yükümlülükler, U.S Hisse Senetleri/TV, Krediler/TV, Kredi Kar. Zararları/FG, Gelirin% 'Si Olarak Hazine Menkul Kıymetleri, Menkul Kıymetlere Ödenen Faiz Gelirin% 'Si
Altman, Haldeman, ve Narayanan (1977)	DK/TV, On Yıllık Standart Sapma, HD/TS, DV/KVY, LOG (TV), FVÖK/TV, LOG (FVÖK/Faiz Ödemeleri)

DV: Dönen Varlıklar, KVV: Kısa Vadeli Yükümlülükler, FVÖK: Faiz ve Vergi Öncesi Kazanç, NG: Net Gelir, V: Gelirlerin Kullanım oranı, FG: Faaliyet Giderleri, FGE: Faaliyet Gelirleri, LV: Likit Varlıklar(Nakit, Menkul Kıymetler, Alacaklar), DK: Dağıtılmayan Kar, HD: Hisselerin Toplam Değeri, TV: Toplam Varlıklar, TS: Toplam Sermaye, TB: Toplam Borç, ÇS: Çalışma Sermayesini ifade etmektedir.

Tablo 2.2'de gösterilmekte olan dört çalışmada kullanılan finansal oranlar farklıdır. Sadece Altman (1968) ve Altman, Haldeman, ve Narayanan (1977) FVÖK/TV oranını ortak kullanmışlardır. Kullanılan oranların farklı oluşu sınıflandırma performansını etkilemektedir. Bu sebeplerden dolayı model oluşturulurken kullanılacak finansal oranlar problemin türüne göre seçilmektedir.

2.1.2.1. Çok değişkenli modellerde kullanılan istatistiksel teknikler

Çok değişkenli sınıflandırma, araştırmacının araştırma hedefi hakkında yapması gereken üç yargıya dayanmaktadır:

- Değişkenler, bazı teorilere dayanarak bağımsız ve bağımlı sınıflandırmalara bölünebilir mi?
- Eğer yapabilirlerse, tek bir analize bağımlı olarak kaç tane değişken ele alınır?
- Hem bağımlı hem bağımsız değişkenler nasıl ölçülür?

Çok değişkenli uygun tekniğin seçimi bu üç soruya vereceğimiz cevaba bağlıdır. İlk sorunun cevabı veri değişkenlerinin bağımsız ve bağımlı sınıflandırmalara nasıl bölünebileceği ile ilgilidir. İkinci sorunun cevabı kaç değişkeninin analize dahil edilebileceği ile ilgilidir. Üçüncü sorunun cevabı ise kullanılacak değişkenlerin nasıl ölçüleceği ile ilgilidir. Bir bağımlılık tekniği, bir değişken veya değişken setinin önceden tanımlanacak veya başka değişkenler tarafından açıklanacak bağımlı değişken olarak tanımlandığı bir yöntem olarak tanımlanabilir. Bir bağımlılık tekniğinin bir örneği çoklu regresyon analizidir. Tersine, bir karşılıklı bağımlılık tekniği, tek bir değişkenin ya da değişken grubunun bağımsız ya da bağımlı olarak tanımlanmadığı bir yöntemdir ve kümedeki diğer değişkenlerin eş zamanlı analizini içermektedir (Hair vd., 2014: 12-15).

Çok değişkenli modeller oluşturulurken farklı istatistiksel tekniklerden yararlanılabilir. İstatistiksel teknikler şu şekilde sıralanabilir:

- Diskriminant Analizi
- Çok Değişkenli Regresyon Modeli
- Logit Model
- Probit Model

2.1.2.1.1. Diskriminant analizi


Diskriminant analizi, kümelerin bilinen bir durum olduğu durumlarda kullanılır. Diskriminant analizinin amacı, bilinen bu gruplara bir gözlemi veya birkaç gözlemi sınıflandırmaktır. Örneğin, kredi puanlamada, bir banka geçmiş deneyimlerden iyi müşterileri (herhangi bir sorun olmadan kredisini geri ödeyen) ve kötü müşterileri (kredilerini ödemede zorluklar gösteren) olduğunu bilir. Yeni bir müşteri bir kredi istediğinde, banka kredi verilip verilemeyeceğine karar vermek zorundadır. Ayrımcılık kuralı, müşteriye mevcut iki gruptan birine ayırmak zorundadır ve diskriminant analizi olası bir “kötü karar” riskini değerlendirmelidir (Härdle ve Simar, 2007).

Diskriminant analizi, ölçüm alınan bir birimin sonlu sayıda bilinen farklı gruplardan birine atanmasını gerçekleştiren bir tekniktir. Atama sürecinde birim aldığı gözlem değerine göre ait olduğu gruptan başka bir gruba atandığında hata yapılmış olur. Diskriminant analizinde meydana gelen bu hataya, hata oranı ya da hatalı sınıflandırma olasılığı denilmektedir. Bu istatistiksel teknikte amaç, gruplara atama işleminin minimum hatayla yapılmasıdır (Atakan ve Karabulut, 2003: 53). Diskriminant analizi, bağımlı değişkenin nominal, bağımsız değişkenlerin de aralık veya oran ölçekli olduğu çalışmalarda kullanılan parametrik çok değişkenli bir istatistiksel yöntemdir (Öz vd., 2011: 51).

Daha önce ifade edildiği gibi diskriminant analizi iki ya da daha fazla grubu ayırmaya yönelik kullanılır. Bir pazarlama müdürünün ürünlerini kullanan tüketicileri sınıflandırmasında, telefon şirketinin yönetiminin, bir, iki, üç veya daha fazla telefon hattına sahip haneler arasında en iyi ayırım yapan özelliklerin gruplandırılmasında diskriminant analizi kullanılabilir. Bu örneklerin her biri iki ya da daha fazla grup arasındaki ayırımı içerir. Çoklu grup diskriminant analizi bu amaçlar

için uygun bir tekniktir. Çoklu grup diskriminant analizi ile iki gruplu diskriminant analizinin bir fark dışında amacı aynıdır. İki gruplu diskriminant analizinde iki grubu birbirinde ayırmak için yalnız tek diskriminant fonksiyonu bulunurken çok gruplu yani ikiden fazla grubun bulunduğu analizde ayırım tek bir diskriminant fonksiyonu ile yapılamamaktadır (Sharma, 1996: 287).

Diskriminant analizi, çalışmanın amacına göre farklılaşmaktadır. Problemin belirlenmesinden sonra bağımsız değişkenlerin seçilmesi ile oluşturulan yapı çeşitli varsayımları da içererek analiz oluşturulur. Özellikle başarılı-başarısız, doğru-yanlış, kullanan-kullanmayan, hatalı-hatasız gibi birimlerin hangi iki gruptan birine ait olduğunun tespit edilmesidir. Buradaki amaç bağımsız değişkenler yardımıyla sınıflandırmanın hatasız yapılmasıdır. Şekil 2.1 iki gruplu diskriminant analizinin hesaplanmasını açıklamada yardım etmektedir.



Şekil 2.1. İki Gruplu Diskriminant Analizinin Grafikselleştirilmesi (Hair vd., 2014)

Şekilde görüldüğü üzere A ve B olmak üzere iki grup ve V1 ve V2 olmak üzere iki ölçüm yaptığımızı varsayalım. Değişken V1 ile değişken V2'nin iki grup üyelerinin arasındaki ilişkinin dağılım grafiği çizilebilir. Şekil 2.1'de küçük noktalar B grubunun üyelerinin değişken ölçümlerini gösterirken, geniş noktalar A grubunu göstermektedir. Geniş ve küçük noktaların etrafında çizilen elipsler, her grupta

genellikle yüzde 95 veya daha fazla olan noktaların önceden belirlenmiş bir kısmını kapsayacaktır. Eğer elipslerin kesiştiği iki noktadan düz bir çizgi çizer ve çizgi yeni bir Z eksenine yansıtılırsa tek değişkenli A ve B dağılımları (gölgeli alan tarafından temsil edilen) arasındaki örtüşmenin, bundan daha küçük olduğunu söylenebilir. Şekil 2.1 ile ilgili dikkat edilmesi gereken önemli nokta, Z ekseninin A ve B gruplarının iki değişkenli profillerini tek sayı olarak (diskriminant skorları) ifade etmesidir. V1 ve V2 orijinal değişkenlerinin doğrusal bir kombinasyonunu bularak, sonuçları bir diskriminant işlevi olarak yansıtılabilir. Örneğin, büyük ve küçük noktalar diskriminant Z skorları olarak yeni Z eksenine yansıtılırsa, sonuç, grup farkları hakkındaki bilgileri (V1, V2 olarak gösterilen) tek bir noktaya (Z skorları) dönüştürür (A ve B dağılımları ile gösterilen eksen). Özetlemek gerekirse, belirli bir diskriminant analiz problemi için, bağımsız değişkenlerin doğrusal bir kombinasyonu türetilir ve bu da her gruptaki her nesne için bir dizi diskriminant puanla sonuçlanır. Diskriminant puanları, gruplar arasındaki varyansı en üst düzeye çıkarmak ve aralarındaki varyansı en aza indirmek için istatistiksel kurala göre hesaplanır. Gruplar arasındaki varyans gruplar içindeki varyansa göre büyükse, ayırıcı işlevin grupları iyi ayırdığı söylenebilir (Hair vd., 2014).

Çoklu diskriminant analizinde, iki ya da daha fazla grubun ayrımını sağlayacak z fonksiyonunun belirlenmesine çalışılmaktadır. Fonksiyon (z) aşağıdaki denklem ile ifade edilmektedir (Joy ve Tollefson, 1975: 724):

$$Z_i = \beta_0 + \beta_1 X_{i1} + \beta_2 X_{i2} + \beta_3 X_{i3} + \dots + \beta_m X_{im} \quad [2.1]$$

Z_i = Diskriminant fonksiyon değeri

β_j = Diskriminant katsayıları

X_j = Bağımsız değişkenler

Yukarıdaki denklemde görüldüğü üzere diskriminant fonksiyonu bağımsız değişkenlerin doğrusal bir fonksiyonudur.

Çok değişkenli diskriminant modellerinde, analiz yapılan işletmenin finansal özellikleri, tek bir diskriminant skorunda birleştirilmektedir. Bu skor $-\infty$ ile

$+\infty$ arasında bir deęer alır ve analiz yapılan iřletmenin finansal durumunun bir gstergesi olan tek boyutlu bir ldr. Genelde ortaya ıkan dřk diskriminant skoru, iřletmenin finansal yapısının gl olmadığını gstermektedir. İřletmenin finansal yapısını ngrmede kullanılan deęiřkenlerin bir diskriminant skoru olarak elde edilmesi, iřletmenin bařarısızlıęının tahmininde faydalar saęlamaktadır.

Sınıflandırma iřlemlerinde, ok deęiřkenli diskriminant analizi ile iřletmeler bařarılı/bařarısız řeklinde gruplandırılmaktadır. Gruplara atama yapılırken yani sınıflandırma iřlemi yapılırken, ok deęiřkenli diskriminant modeli iin bir kopuř deęerine gre iřlem yapılmaktadır. Eęer diskriminant skoru (Z), kopuř deęerinden daha kkse bařarısız gruba, diskriminant skoru kopuř deęerine eřit ya da byk ise bařarılı gruba ait olarak deęerlendirilir. Bazen tersi durumlarda olabilmektedir. ok deęiřkenli modellerde yaptığımız gruplandırma yani sınıflandırma doęruluęu, genellikle 1.tip ve 2. tip hata oranlarına dayanarak deęerlendirilir. 1. tip hata bařarısız iřletmeleri bařarılı olarak sınıflandırma iken 2. tip hata bařarılı iřletmeleri bařarısız olarak sınıflandırma hatasıdır. Performans lm olarak toplam doęrulama sınıflandırma yzdesi oranı da kullanılabilir. Performans lmlerinde belirli bir kopuř (Z) deęerinin saptanmasını gerektirmeyen bařka llerde kullanılabilir (Torun 2007: 38).

2.1.2.1.2. ok deęiřkenli regresyon analizi

oklu regresyon analizi baęımlı deęiřken ile birden ok baęımsız deęiřken arasındaki iliřkiyi incelemek iin kullanılır. ok deęiřkenli regresyon modeli, doęrusal ve doęrusal olmayan regresyon modelleri řeklinde ayrılmaktadır. Bu ayırma deęiřkenler arasındaki iliřkiye baęlı olarak gerekleřtirilmektedir. Finansal vakaların aıklanmasında oęunlukla ok deęiřkenli doęrusal model kullanılmaktadır. Eęer baęımlı deęiřkenlerdeki deęiřmeler birden fazla baęımsız deęiřkenle aıklanabiliyorsa ok deęiřkenli regresyon analizi kullanılır. ok deęiřkenli doęrusal regresyon analizinde ařaęıdaki hususlara dikkat edilmelidir (elik, 2009: 45):

- Veriler nicel yani llebilir olmalı.
- Regresyon eřitlięini modellemeden nce, hangi deęiřkenlerin baęımsız, hangisinin baęımlı deęiřken olarak kalacaęının kararlařtırılması gerekmektedir.

Birden fazla bağımsız değişken ile bir bağımlı değişken arasındaki ilişkiyi ifade eden regresyon denklemi aşağıdaki gibi gösterilebilir.

$$Z = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \beta_3 X_3 + \dots + \beta_k X_k + \varepsilon_i \quad [2.2]$$

Z= Regresyon değeri

β_0 = Sabit Değeri

β = Bağımsız değişkenlerin regresyon katsayıları

ε_i = Hata terimi

Çoklu regresyon modeli ekonomi ve finans alanında sıklıkla kullanılan modeldir. Çoklu regresyon modelinin finansal başarısızlığın tahmininde kullanılması, klasik modelden bağımlı değişkenin değeri açısından farklıdır. Bu farklılık, bağımlı değişkenlere, işletmelerin finansal açıdan başarılı olma ya da olamama durumlarına göre 0 ve 1 değerlerinin verilmesidir. Oluşturulan regresyon fonksiyonu ile işletmelerin finansal açıdan başarılı ya da başarısız olma durumlarını öngörürken, söz konusu işletmenin Z değeri kopuş değeriyle (Z^*) ile karşılaştırılır. Eğer $Z < Z^*$ ise işletme finansal açıdan başarısız, $Z > Z^*$ durumunda ise işletme finansal açıdan başarılıdır şeklinde sınıflandırılabilir (Aktaş vd., 2003: 5-6).

Yukarıda verilen [2.2] numaralı regresyon denklemi doğrusal regresyon modeli şeklinde adlandırılır. Çünkü denklem liner parametreler içermektedir. Yani katsayılar β bağımsız değişkenlerin ve eklenen hata teriminin basit doğrusal çarpanıdır. Modelin bağımsız değişkenlerde doğrusal olması gerekmez (R. Freund ve Wilson, 2003: 336). Çoklu doğrusal regresyon modellerinin uygulanabilmesi ve çıktılarının doğru bir şekilde yorumlanabilmesi için bazı koşulların oluşması gerekmektedir. Bu koşulları şu şekilde sıralanabilir (Dogan ve Yilmaz, 2017: 3):

- Veriler normal dağılım sergilemelidir.
- Bağımsız değişkenler ile bağımlı değişkenler arasında doğrusal bir ilişkinin olması gerekmektedir.
- Eşvaryanslılığın (homoscedasticity) sağlanmış olması gerekmektedir.
- Çoklu bağıntı (multi-collinearity) problemi olmamalıdır.

- Hata terimleri birbirinden bağımsız olmalıdır.

2.1.2.1.3. Logit model

Logit modeller, genelleştirilmiş doğrusal modelin belirli koşullar durumunda oluşturulmuş özel durumlarıdır (İnal vd., 2006: 58). İşletmelerin mali başarı durumlarını öngörmeye çok değişkenli diskriminant ve regresyon modellerinin bazı kısıtlayıcılarının olduğu fark edilince kuramsal olarak daha üstün bir teknik olan logit modeli kullanılmaya başlanmıştır. İşletmelerin mali başarı durumlarını öngörme analizlerinde logit model kullanılarak finans alanında öncü olmuş eser Ohlson (1980) tarafından geliştirilmiştir (Salur, 2015: 45).

Logit regresyona tabi olan ve ikili bağımlı değişkenler için kullanılan doğrusal olmayan ama uygun dönüşümler ile doğrusallaştırılabilen bir regresyon modeli olarak logit modeller kullanılmaktadır. Birikimli dağılım fonksiyonu açısından probit modellerden ayrılmaktadır. Logit model lojistik birikimli dağılımdan türetilen modeldir. Literatürde logit model, lojistik regresyon modeli olarak da adlandırılır. Bağımlı değişkenin 0 ve 1 değerlerini alması ve bu iki değer bağımsız değişkenler ile arasındaki ilişkinin araştırılmasında lojistik regresyon kullanılmaktadır. Lojistik regresyon daha çok durum kontrolü analizlerinde kullanılır. Literatürde bu modeller biyoloji, tıp, ekonomi, finans gibi birçok alanda kullanılmaktadır (Cebeci, 2012: 129).

İşletmelerin finansal başarısızlığının tahmin edilmesinde kullanılan logit model, çoklu regresyon modeli ve diskriminant analizinin parametreleri hesaplandıktan sonra, bağımlı değişken değerinin 0-1 aralığı dışına taşması muhtemeldir. Z değerinin, bağımsız değişkenlerinin alacağı değer ne olursa olsun 0-1 aralığında tutulabilmesi, birikimli bir olasılık fonksiyonunun kullanılması ile mümkündür (Aktaş vd., 2003: 5-6). Logit fonksiyonu aşağıdaki gibi yazılabilir (Aktaş, 1993: 47-48):

$F(Z_i)$ logit olasılık fonksiyonunu ifade etmek üzere,

$$F(Z_i) = \frac{1}{1 + e^{-Z_i}} = \frac{1}{1 + e^{-(\beta_0 + \sum_{j=1}^k \beta_j x_{ij})}} \quad [2.3] \text{ ya da}$$

$\exp(Z_i) = e^{(Z_i)}$ olmak üzere,

$$F(Z_i) = \frac{\exp(Z_i)}{1 + \exp(Z_i)} \quad [2.4] \text{ şeklinde ifade etmek mümkündür.}$$

Dolayısıyla $\text{Log} \frac{F(Z_i)}{1-F(Z_i)} = Z_i$ [2.5] veya

$$\text{Log} \frac{F(Z_i)}{1-F(Z_i)} = \beta_0 + \sum_{j=1}^m \beta_j * X_{ij} \quad [2.6] \text{ ifadeleri elde edilebilir.}$$

Eğer $F(Z_i) = P_i = \text{Pr ob}(Y_i)$ [2.7] olarak ifade edilirse, logit model için;

$$\text{Log} \frac{P_i}{1-P_i} = \beta_0 + \sum_{j=1}^m \beta_j * X_{ij} \quad [2.8] \text{ eşitliği elde edilecektir.}$$

Bu denklemin sol tarafına log-odds oranı denir. Böylece, log-odds oranı açıklayıcı değişkenlerin lineer bir fonksiyonudur. Doğrusal olasılık modeli için P, açıklayıcı değişkenlerin doğrusal bir fonksiyonu olduğu varsayılmaktadır (Maddala, 1992: 328).

Lojistik regresyon, bağımlı değişkenin tahmini değerlerini olasılık olarak hesaplayarak, olasılık kurallarına uygun sınıflama yapma imkânı veren bir istatistiksel yöntemdir. Lojistik regresyon ham veri ya da tablolatırılmış veri setlerini analiz eden bir yöntemdir. Veri yapılarına göre kurulan lojistik regresyon modelleri aşağıdaki gibi yazılabilir (Özdamar, 2013: 524):

İki değişkenli (binary) lojistik modeli:

$$P(Y) = \frac{e^{\beta_0 + \beta_1 x}}{1 + e^{\beta_0 + \beta_1 x}} = \frac{1}{1 + e^{-(\beta_0 + \beta_1 x)}} \quad [2.9]$$

Çoklu (Multiple) lojistik modeli:

$$P(Y) = \frac{e^z}{1 + e^z}, P(Y) = \frac{1}{1 + e^{-z}} \quad [2.10]$$

Burada Z, bağımsız değişkenlerin doğrusal kombinasyonudur ve şu şekilde yazılır:

$$Z = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_p X_p \quad [2.11]$$

β_0 ve β_1, β_p regresyon katsayılarıdır. Regresyon katsayılarının hesaplanması aşağıdaki gibidir.

$$\ln\left(\frac{P(Y)}{Q(Y)}\right) = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_p X_p \quad [2.12]$$

$$\frac{P(Y)}{Q(Y)} = e^{\beta_0 + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_p X_p} = e^{\beta_0} e^{\beta_1 X_1} e^{\beta_2 X_2} \dots e^{\beta_p X_p} \quad [2.13]$$

$$OR_p = \text{Exp}(\beta_p) \quad [2.14]$$

Burada $Q(Y)$, $Q(Y)=1-P(Y)$ [2.15] olarak hesaplanır. Odds Ratio'nun $OR = \frac{P(Y)}{Q(Y)}$ olarak hesaplandığı hatırlanacak olursa her bir parametrenin $\text{Exp}(\beta)$ değerleri OR değerleri olarak alınır. Böylece $\text{Exp}(\beta_p)$, Y değişkeninin X_p değişkeninin etkisi ile kaç kat daha fazla ya da yüzde kaç oranda fazla gözlenme olasılığına sahip olduğunu belirtmektedir (Özdamar, 2013: 525).


2.1.2.1.4. Probit model

Probit model ile logit model birbirine benzemekle birlikte olasılık hesaplanması farklılık gösterir. Eğer $y_i = \beta_0 + \sum_{j=1}^k \beta_j x_{ij} + u_i$ [2.16] eşitliğindeki u_i hatalar normal dağılım izlerse, probit model (normit modeli olarak da adlandırılır ve probit, biyometrik literatüründe kullanılan bir kelimedir) uygulanır. Bu durumda probit modelinde olasılık $P(Z_i)$ aşağıda gösterilen şekliyle kümülatif standart normal dağılım fonksiyonuna göre hesaplanır (Maddala, 1992: 328):

$$P(Z_i) = F(Z_i) = \int_{-\infty}^z \frac{1}{\sqrt{2\pi}} \exp\left(-\frac{t^2}{2}\right) dt \quad [2.17]$$

Probit model, bağımlı değişkenin normal dağıldığını varsayarken, logit model bu bağımlı değişkenin lojistik eğriye dayandığını varsaymaktadır. Logit modelin dağılımı lojistik birikimli dağılım fonksiyonunun kuyruk bölgeleri probit modele göre daha geniştir. Bu iki model benzer neticeler vermesine rağmen iki modelin tahmin edilen ana kütle katsayılarını doğrudan karşılaştırmak olanaksızdır. Fakat Amemiya (1981) tavsiye ettiği bir katsayı ile bu katsayıları karşılaştırılabilmektedir. Doğrusal olasılık modeli belirli sorunları beraberinde

taşımaktadır. Bu sorunlardan en belirgin olanı, tahmin edilen olasılık değerlerinin 0-1 aralığının dışına çıkmasıdır. Bu problemin yok edilmesi amacıyla kullanılan probit model, olasılıkların 0-1 aralığında kalmasını sağlayan doğrusal olmayan bir modeldir (Cebeci, 2012: 131). Şekil 2.2’de verilerin büyüklüğüne göre logit ve probit birikimli dağılımının grafik üzerinde gösterimi yer almaktadır.



Şekil 2.2. Logit ve Probit birikimli dağılımlar (Arzu vd., 2013)

Dağılım özelliklerine göre birbirinden farklılaşan logit ve probit modellerin Şekil 2.2’de birikimli ve lojistik dağılımların uç noktaları dışında, veriler uzak değerler aldığından, örneklem verileri büyük değerler olmadığında, logit ve probit modelleri birbirine yakın sonuçlar verir. Probit ve logit modelleri yapılan analiz ile elde edilen değerlerin karşılaştırılmasında, bazı bilim adamları probit değerinin $\frac{\pi}{\sqrt{3}}$ çarpanı ile çarpılması ile logit değerine ulaşabileceğini söylerken, bazı bilim adamları ise, bu dönüştürme çarpanı olarak 1,6 değerinin kullanılması gerektiğini savunmaktadırlar. En uygun çarpanın, bu bilim adamlarının saptadıkları değerlerin arasında olduğu neticesine varılmıştır (Ergin, 2009: 82-83).

2.2. YAPAY ZEKÂ VE MAKİNE ÖĞRENMESİ MODELLERİ

Yapay zekâ (Artificial Intelligence) son yıllarda birçok alanda yapılan çalışmaların merkezine oturmaktadır (Bench-Capon ve Dunne, 2007: 619). Yapay zekâ ile ilgili ilk dönemlerde yapılan çalışmalar daha çok problem çözme becerisine sahip sistemler oluşturma gayesine odaklanmaktaydı. Bu konudaki ilk çalışmalardan biri olarak Newell, vd. (1958) örnek olarak verebiliriz (Kenneth ve Christian, 1986: 177). Son on yılda yapay zekânın gelecekte insanları, toplumları, firmaları, ülkeleri

ve dünyayı ne düzeyde etkileyeceğine dair birçok tahminde bulunulmuştur (Makridakis, 2017: 47).


Yapay zekânın bilim dalı olarak gelişmesi, 1956 yılında C.Sahannon, M.Minsky ve J.McCarthy'nin uğraşlarıyla başlamıştır. Yapay zekâ ilk defa adını 1956 yılında ABD'de "Makine Zekâsı" konferansında duyurmuştur. Yapay zekâ; insanların zekice hareketler olarak kabul ettikleri davranışların bilgisayarlara yaptırılması ile ilgili bilgisayar bilimleri alt alanıdır. Yapay zekânın asıl amacı insan zekâsına sahip bilgisayarlar geliştirmektir. Yapay zekâ alanında çalışan bilim adamları bir anlamda düşünen bilgisayarlar/makineler geliştirmeye çalışmaktadırlar. Burada düşünce kavramı; bilgisayar programlarının problemleri çözerken gösterdiği yaklaşımların bir insanın gösterdiği davranışlara benzemesi anlamında kullanılmaktadır. Bir programın bunu başarabilmesi için, çözülecek olan problem alanı konusunda yüksek seviyede bilgiye sahip olmalıdır. Böylece, çok dar bir problem alanında insan gibi uzman olan bilgisayar programları geliştirilebilir (Allahverdi, 2002: 1).

İnsanların zeki denilen davranışlarını gösteren zekânın bilim adamları tarafından çeşitli tanımlamaları yapılmıştır. Zekâ, özerk, vücut bulmuş ve esnek bir şekilde ihtiyaçları doğrultusunda güdülenmiş yönelimleriyle eylem gerçekleştirirken öğrenebilen varlıkların düşünsel süreçlerini ifade eder. Bu tanımlama ile yönelimli sistemler kuramı zeki varlıkların ihtiyaçlarına dayandırılmıştır. Önerilen tanımda altı kavramdan bahsedilmektedir. Bunlar (Aydın, 2013: 19):

- Özerk: Tüm varlıkların doğrudan veya dolaylı kontrolü olmaksızın kendi algılarına dayalı, akıl yürütebilen ve karar veren varlık.
- Vücut Bulmuş: İçinde bulunduğu çevreyi etkileyebilecek eylemleri gerçekleştirebilen fiziki olarak var olan varlık.
- Esnek: İhtiyaç halinde sosyal bir şekilde kimi eylemleri gerçekleştirebilen varlık.
- Öğrenebilen: Algılarının, kararlarının ve eylemlerinin sonuçlarını idrak ederek kendi tutum ve davranışlarını değiştirebilen varlık.
- Güdülenmiş: Kendi ihtiyaçlar hiyerarşisi doğrultusunda güdülenmiş varlık.

- Yönelimli: İhtiyaçları doğrultusunda güdülenmiş yönelimleriyle eylem gerçekleştiren varlık.

Yapay zekânın gelişimindeki mimarlardan biri olan ünlü İngiliz matematikçi Alan M.Turing'in 1950 yılında Mind dergisinde kaleme almış olduğu "Computing Machinery and Intelligence" adlı makalesi, yapay zekâ alanında kaleme alınmış en eski çalışmalardan diğeridir. Yapay zekâ konusundaki çalışmalarda yerini bulan Turing'in makalesinin önemi, yapay zekâ konusunda felsefi bir tartışma yaratmasından kaynaklanır. Turing bahsedilen makalesinde, "Makineler düşünebilir mi?" sorusunu sormuş ve kendi sorusuna yanıt aramış, neticede makinelerin düşünemeyeceği konusundaki itirazları ret etmiştir. Turing testinin çeşitli versiyonları bulunmakla beraber esasında bir kullanıcı, kodlanmış bir yapay zekâ yazılımı ve bir insan vardır. Turing testinin orijinal hali iki aşamalı olmasına rağmen, bilgisayarın zeki olup olmadığının testi şöyledir. Şekil 2.3'de görüldüğü gibi yapılan teste kullanıcının görsel ve işitsel ön yargılarını ortadan kaldırmak için sadece bir klavye ve monitör aracılığıyla iletişim kurulur. Kullanıcı test uygulanan yapay zekâ yazılımı ile sohbet eder. Kullanıcı klavyeden bilgi girişi ile sorularını sorarken, karşısındaki yapay zekâ yazılımından veya insandan gelen cevaplar monitöre metin olarak yansıtılır. Yapılan bu sohbet aşamasında kullanıcı kimin bilgisayar kimin insan olduğunu ayırt etmeye yönelik sorular sorar. İnsan kendisinin insan olduğunu ispatlamaya çalışırken, zeki olup olmadığı araştırılan bilgisayar yazılımı da, aynı zamanda kendisinin insan olduğunu kullanıcıya inandırmaya çalışır. Kullanıcı sorduğu sorular ve aldığı cevaplar ile kullanıcılardan hangisinin bilgisayar yazılımı olduğunu anlamaya çalışır. Bilgisayar bir insan gibi davranmak adına ve kandırabilmek için kimi zaman sorulan sorulara yanlış cevaplar verebilmektedir. Test sonucunda eğer kullanıcı kimin bilgisayar olduğunu bilemezse, yapay zekâ yazılımı testi başarı ile geçmiş olur. Yazılan birçok yapay zekâ yazılımları bu teste girmeye gerek duyulmayacak kadar sınırlı bir düzeydedir (Yıldız, 2009: 23-24).



Şekil 2.3. Turing Testi (wikipedia, 2018)

Yapay zekâ ileriki dönemlerde ülkelerin en önemli gündemi olacaktır. Yapay zekâ teknolojilerine önem veren ülkelerin kalkınma ve büyüme hızı artacaktır. Günümüzde bazı ülkelerin yapay zekâ bakanlığı kurmalarının sebeplerinden biri de budur. Yapay zekâ hayatımızın her alanına girecek bir güç olacaktır. Savunma sanayisinden eğitime, işletmelere, fabrikalara kadar birçok alanda etkili olacaktır. Yapay zekânın avantajları aşağıdaki gibi sıralanabilir (Yıldız, 2009: 24-26):

- Yapay zekâ kalıcıdır,
- Yapay zekâ daha kolay belgelendirilir,
- Yapay zekâ daha istikrarlıdır,
- Yapay zekâ daha objektiftir,
- Yapay zekâ daha verimlidir,
- Yapay zekâ güncellenebilir,
- Yapay zekâ geliştirilebilir,
- Yapay zekânın tahmin gücü ile birçok sorun önceden ortadan kaldırılabılır,
- Yapay zekâ ülkeleri güçlü kılar, ekonomik büyüme sağlar.

Yapay Zekâ'nın değişik boyutlarını inceleyen farklı yaklaşımlar mevcuttur. Birçok dala ayrılan Yapay Zekâ farklı araştırmacılara göre farklılıklar arz eder. Bunlardan bazıları şu şekilde sıralanabilir (Allahverdi, 2002: 2-3):

- Uzman sistemler,
- Yapay sinir ağları,
- Genetik algoritmalar,
- Endüktif öğrenme,
- Veri tabanlı muhakeme,

- Model tabanlı muhakeme,
- Monotonik olmayan muhakeme veya doğruyu koruma mekanizması,
- Geometrik muhakeme,
- Dağıtılmış yapay zekâ sistemleri,
- Paralel yapay zekâ sistemleri,
- Zeki etmenler,
- Doğal dil işleme,
- Nesne tabanlı zeki sistemler,
- Zeki veri tabanları,
- Bilimsel buluşların modellenmesi,
- Kavramsal grafikler,
- Bilimsel keşifler,
- Zeki multimedya birimleri,
- Kaos teorisi,
- Mantık programlama,
- Zeki öğretim sistemleri,
- Bulanık mantık,
- Destek vektör makineleri.

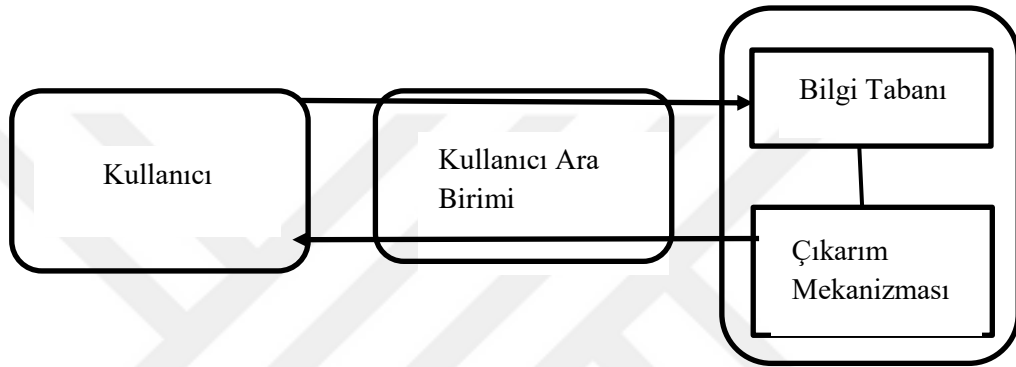
Bu çalışmanın temelini Yapay Zekâ modelleri oluşturmaktadır. Yukarıda sıralanan Yapay Zekâ modellerinin hepsine yer vermeden daha sık kullanılan modeller hakkında bilgi verilecektir.

2.2.1. Uzman sistemler (US)

Uzman sistemler (US), insanın davranış, hareket ve deneyimlerini örnek olarak problemlerin çözümüne odaklanan bilgi tabanlı bilgisayar programlarıdır. US, kararların tamamı ile programlanamayan sadece kararların bir bölümünün bilgi sistemini üstlenmekle sorumludur. US karar destek sistemleri oluşturmasından sonra, uygun kararların otomatik olarak verilmesi nedeniyle bu tip sistemlere zeki sistemler de denilmektedir. US, analitik modelleri kurulamayan gerçek hayattan olan problemlerin, sezgisel modellerle yorumlanmasını ve çözüme ulaşılmasını sağlamaktadır. US, karşılaşılan problemlerin çözümüne farklı alternatifler getirerek, yapılan işlem ve süreçlere yeni bir boyut getirmektedir. US, etkin ve hızlı çözümler

bekleyen hayatın içinde rastlanan birçok probleme hızlı çözümler bulmaktadır. US yardımıyla işletme yöneticileri, çözümü olmadığı düşünülen karmaşık ve zor problemler ile daha çok bilgi işlemeyi mümkün kılan, etkili programlanmış iş istasyonlarına sahip olmaktadır. İşletme yönetimi iş istasyonları yardımıyla verdikleri üretimdeki ürünlerin miktar ve kalitelerini simültane deneme imkanına sahip olurlar (Ersöz, 1998: 53-54).

Şekil 2.4’de US genel yapısı incelendiğinde bilgiyi saklayabildiği görülmektedir.



Şekil 2.4. Uzman Sistemlerin Genel Yapısı (İçen ve Günay, 2014:37)

Sistemde mevcut olan “Bilgi Tabanı”, önceden bilinen bilgiyi taşır. Uzman sistemlerin uzmanlık bilgisini makineye aktarması için mevcut bilginin istenen şekilde yazılması gerekmektedir. Sistemde bulunan “Bilgi Tabanı”, veri tabanı ve kurallar tabanından oluşur. Mevcut veriyi kullanarak kullanıcıya sunmak için kurallar tabanından yararlanır. Çıkarım mekanizması ise, bilgi tabanında bulunan bilgiyi kullanarak sorulara uygun cevapların oluşturulduğu yerdir. Kullanıcı ile iletişim halinde olan uzman sistemler, kullanıcıdan sadece gerçekleşen duruma ait bilgiyi alır. Bu durum “Kullanıcı Ara Birimi” sayesinde mümkündür. Aldığı bilgiyi “Çıkarım Mekanizmasından” işler ve bilgi tabanından çıkarabileceği sonuçları yine “Kullanıcı Ara Birimi” ile aktarır. Uzman sistemler kendini geliştirebilir (İçen ve Günay, 2014: 40).

US, YZ araştırmalarıyla elde edilen zeki bilgisayar programlarıdır. YZ’nın bilimsel amacı, akıllı davranış sergileyen bilgisayar programları yardımıyla zekâyı anlamaktır. Aslında uzman sistemler basit ve etkileyici bir paradigmaya dayanmaktadır: uzmanlar diğerlerinden daha iyi performans gösterebildikleri için,

benzersiz bilgiler ayıklanır, bilgisayarlı bir sistemde saklanır ve daha sonra "kullanıcılar" tarafından uygulanabilmeleri için kullanılabilir hale getirilirse herhangi bir kullanıcı tarafından uzman düzeyinde bir performans elde edilebilir (Romem, 2010: 8). US, işin uzmanlarının başarabildiği görevleri yüksek performans seviyesine ulaşılarak yapmaya çalışmaktadırlar (Orhun, 1986: 245). US karar vericilere tavsiye vermek üzere tasarlanmıştır ve insan uzmanlarından çıkarılan sezgisel kurallara dayanmaktadır. Son yıllarda, bu tür bir dizi sistem geliştirilmiştir. Örneğin; risk yönetimi alanındaki analistler kimyasal sızıntıların neden olduğu acil durumlarla ilgili karar vermeyi desteklemek için uzman sistemler tasarlamışlardır (Fiksel ve Covello, 1986: 85).

Bir bilgisayar tarafından sembolik çıkarım veya akıl yürütme kavramları ve yöntemleri bu çıkarımları yapmak için kullanılan bilginin makinenin içinde nasıl temsil edileceği ile ilgilidir. Bununla birlikte, geleneksel yazılım algoritmaları ve US arasında bir fark vardır. Geleneksel algoritmalar açıkça tanımlanmış bir sonuca sahip olmasına rağmen, uzman bir sistem cevap veremeyebilir veya bir olasılık olan birini sağlayabilir. Burada kullanılan metodoloji sezgisel programlamadır ve bakış açısına bağlı olarak, sistem ve bilgi tabanlı veya kural tabanlı sistem terimleri genellikle eş anlamlı olarak kullanılır (Hemmer, 2008: 9). Yöneticilerin en önemli görevlerinden biri de işleyiş süreçleri hakkında karar almaktır. Karar analizi yönetimi işletmeler açısından oldukça önemlidir. Hem US hem de karar analizinin görevi yöneticilerin bilinçli ve verimli karar vermelerine yardımcı olmaktır. Karar analizi ile US birbirini tamamlayıcı güçtedirler (Keeney, 1986: 155). İnsan uzman kararlarının gerçek ve görünen yetersizliğine rağmen yapay zekâ araştırmacıları US en iyi şekilde tasarlandığını varsayarlar (Schmalhofer, 1986: 283).

US kullanıldıkları alanlara göre birçok faydası vardır. Bu faydalar aşağıda sıralanmıştır (İçen ve Günay, 2014: 41):

- Verimlilik: US insandan hızlı çalışır. Bu nedenle insan iş gücü ve maliyet tasarrufu sağlar.
- Kalite: US tutarlı sonuçlar üreterek kaliteye katkıda bulunur.
- Tutarlılık: İnsan uzmanı, konu hakkında hatalı harekette bulunabilir fakat US konu hakkında tüm detayları tarayarak uygun netice verir.

- Esneklik: US bilgi tabanları güncellenebildiğinden esnektir.
- Kapsamlık: Konu hakkında birden çok uzmanın aynı düşüncede olması imkânsızken US yardımıyla birden çok uzmandan alınan uzmanlık tecrübe ve bilgisi birleştirilebilir.
- Karar Süresi: US karar alma süresi, insan uzmanlarından daha kısadır.
- Güvenirlik: US hızlı çalışan bilgisayar programlarıdır. Bilgi tabanındaki bilgiyi analiz ettiği için güvenilir sonuçlar elde edilir.

Ayrıca yukarıda sayılanların dışında US bir bilgisayar programıdır ve diğer programlar ile entegre olabilir (Bielawski ve Lewand, 1991: 20).

2.2.2. Bulanık mantık

Bulanık mantık, mantıksal uygulamalarda insan davranışlarına benzer bir şekilde, bilgisayara yardım eden bir bilgisayar mantık devrimidir (Kıyak ve Kahvecioğlu, 2003: 63). Bulanık mantık için “net olmayan bir dünyanın gri ve sağduyulu resimlerini üretmeleri için bilgisayarlara yardımcı olan makine zekâsı biçimidir” şeklinde bir tanımlama da yapmak mümkündür (Alcı, 2002: 8). Bulanık mantık diğer adıyla Puslu Mantık kavramı ilk defa 1921 yılında Bakü’de doğmuş olan Lütü Ali Askerzade tarafından kullanılmıştır. Sonraki senelerde kısaca “Zadeh” adıyla tanınacak olan Askerzade, 1965 senesinde “Fuzzy Sets” adlı makalesi ile alanda devrim sayılacak fikirleri ileri sürmüştür (Ural, 2010). Matematiksel yöntemlerin uygulanmasını zorlaştıran belirsizlik durumları Zadeh’in (1965) ortaya attığı bulanık küme teorisi ile aşılmıştır (Oruç ve Yılmaz, 2013: 246).

Zadeh (1965) yazmış olduğu ve bulanık mantık alanında bir devrim olan makalesi aşağıdaki şekilde özetlenebilir (Elmas, 2007: 186):


- Bulanık mantıkta, net ifadelerle dayanan düşünme yerine, yaklaşık ifadeler kullanılmaktadır.
- Bulanık mantıkta tüm değerler $[0,1]$ aralığında bir derece ile gösterilmektedir.
- Bulanık mantık içinde dilsel ifadeler büyük, küçük, çok az gibi kelimelerle anlatılmaktadır.
- Her mantıksal düşünce bulanık sistem haline dönüştürülebilmektedir.

- Matematiksel olarak çok zor elde edilen sistemler için uygundur.
- Bulanık mantık tamamıyla bilinmeyen ve eksik girilen bilgilere göre işlem yapma yeteneğine sahiptir.

Zadeh (1965) çalışmasında, insan zekâsının yaptığı önermelerin kesin değeri yoksa veya belirsizse, bulanık mantığın devreye gireceğini belirtmiştir. Bulanık mantık, yapılan önerme uç noktalarda olmayıp ara değerler içinde (ılık, biraz, normal vb.) yer alması durumunda kullanılmaktadır. Burada mantıksal bir yapı söz konusudur. Klasik mantık gibi bulanık mantıkta önermelerin doğruluğu ile ilgilidir. Ancak gerçek dünyada önermeler genellikle kısmen doğrudur. Buna ek olarak, bu terim, keskin olarak net olamayan önermelerde kullanılmaktadır. Bazı durumları karakterize etmek oldukça zordur (Siler ve Buckley, 2005: 37). Bu durum şöyle örneklendirebilir. Şekil 2.5’de görülen klasik mantığa göre sıcaklık 16 santigrat derece ise soğuktur. Ancak Şekil 2.6’daki bulanık mantık teorisine göre ise 16 santigrat derece sıcaklık için “sıcak” ya da “soğuk” şeklinde keskin ifadeler kullanılmaz. Çünkü 16 santigrat derece sıcaklık değeri belli bir derecede sıcak kümesine ve belli bir derecede soğuk kümesinin üyesidir. Şekil 2.6’daki küme mantığı insanın düşünme yeteneğine daha uyumludur (Subaşı vd., 2010: 47).




Şekil 2.5. Klasik Mantık (Subaşı vd., 2010:48)



Şekil 2.7. Üçgen Üyelik Fonksiyonu

Yamuk üyelik fonksiyonu: Şekil 2.8’de gösterildiği gibi $(a_1, 0)$ başlangıç (a_2) ile (a_3) arasında bulunan tepe doğrusu ve $(a_4, 0)$ bitiş noktalarıyla tanımlanmaktadır (Güner ve Çomak, 2014: 191):

$$\mu_A(x) = \begin{cases} 0, & x < a_1 \\ \frac{x-a_1}{a_2-a_1}, & a_1 \leq x \leq a_2 \\ 1, & a_2 \leq x \leq a_3 \\ \frac{a_4-x}{a_4-a_3}, & a_3 \leq x \leq a_4 \\ 0, & x > a_4 \end{cases} \quad [2.20]$$




Şekil 2.8. Yamuk Üyelik Fonksiyonu

Gauss üyelik fonksiyonu: Şekil 2.9’da Gauss üyelik fonksiyonu gösterilmektedir. Burada c , Gauss eğrisinin merkezini, σ ise genişliğini ayarlayan

parametrelerdir. $c = 0$ durumunda standart Gauss fonksiyonu elde edilir (Güner ve Çomak, 2014: 191), (Alcı ve Etçibaşı, 1998: 21):


$$\mu_A(x) = e^{-\frac{(x-c)^2}{2\sigma^2}} \quad [2.21]$$



Şekil 2.9. Gauss Üyelik Fonksiyonu ve Grafiği

Bell üyelik fonksiyonu için a , b , c parametreleri kullanılır. Bell üyelik fonksiyonu ve grafiği Şekil 2.10'da gösterilmiştir.


$$Bell(x; a, b, c) = \frac{1}{1 + \left| \frac{x-c}{a} \right|^{2b}} \quad [2.22]$$



Şekil 2.10. Bell Üyelik Fonksiyonu ve Grafiği

Sigmoid üyelik fonksiyonu için a ve c parametreleri kullanılmıştır. Sigmoid üyelik fonksiyonu ve grafiği Şekil 2.11’de gösterilmiştir. Grafikte (a) eğim değerini kontrol eder ve (c) geçiş (crossover) noktasını temsil etmektedir (<https://en.wikipedia.org>, 2008).

$$\text{sig}(x; a, b, c) = \frac{1}{1 + e^{-a(x-c)}} \quad [2.23]$$



Şekil 2.11. Sigmoid Üyelik Fonksiyonu ve Grafiği

2000’li yılların başına gelindiğinde finans alanında da bulanık mantık kullanılmaya başlanmıştır. Bulanık mantıktan finans alanında genellikle hisse senedi fiyat tahmini, risk analizi, portföy oluşturma gibi analizlerde yararlanılmaktadır. Yapılan çalışmaların büyük bir kısmı yurtdışı çalışmalar olduğundan ülkemizde de bu alanda yapılacak çalışmalar önem taşımaktadır. Özellikle ABD’de Asya kökenli bilim adamlarının bu konuda çalışmalar yapmasına rağmen batı kökenli bilim adamları daha ilgisiz kalmışlardır. Bilimsel temeli Aristo mantığına dayanan batı kültürünün, altyapısı farklı bir mantığa dayanan yeni bir alana uyum sağlaması kolay olmamıştır. Ancak gelecek yıllarda yapay zekâ ve alt alanı olan bulanık mantık daha çok alanlarda uygulamaya dâhil olacaktır (Birgili vd., 2013: 123).

Klasik yaklaşımlar ile karşılaştırıldığında, bulanık mantık kuramının bazı avantajları ve dezavantajları ortaya çıkmaktadır (Elmas, 2007: 198):

Avantajları

- İnsan beyin yapısı ile düşünme tarzına en yakın olması nedeniyle bulanık mantık yaklaşımı bir üstünlük doğurmaktadır.

- Cebirsel bir modele ihtiyaç duymayan bulanık mantık, modeli iyi tanımlanmamış, zamanla değişen ve doğrusal olmayan yapılarda oldukça başarılı olmaktadır.
- Bulanık mantık yaklaşımında, işaretler ön işlemeye tabi tutulmakta böylelikle geniş bir alana yayılan değerlerin az sayıda üyelik işlemleriyle daha hızlı sonuca ulaşılmaktadır.

Dezavantajları

- Bulanık mantık uygulamaları uzman deneyimlerinden yararlanarak hazırlandığından üyelik fonksiyonlarını ve bulanık mantık kurallarını makineye tanımlamak kolay değildir.
- Sistemin kararlılık, gözlemlenebilirlik ve denetlenebilirlik analizlerinin yapılmasında ispatlanmış bir yöntem yoktur. Bu durum bulanık mantığın bir sorunudur.
- Bulanık mantık uygulamalarında üyelik fonksiyonlarının değişkenleri sadece o sisteme özeldir ve başka sistemlere entegre edilmesi çok zordur.

2.2.3. Genetik algoritmalar (GA)

Günümüzde “evrimsel programlama” diye adlandırılan uygulamalar 20. yüzyılın altmışlı yıllarında Amerika Birleşik Devletleri ve Almanya’da çalışılmaya başlanmıştır. Bilgisayar biliminde kopyalama mekanizmasının iki basit yaklaşımı vardır. Bunlar; evrim stratejileri ve genetik algoritmalarıdır. Genetik algoritmalar, biyoloji bilim dalındaki süreçlerin örnek alındığı bir yöntemdir. Evrim ve mutasyon gibi terimlerin algoritmik olarak benzetilmesi ile matematiksel ifadeye dönüştürme işlemidir. Genetik özelliklerin nesilden nesile aktarılırken değişimini temel alan GA görece güçlü ve amaca uygun özelliklerin korunmasını, zayıf ve amaca ters özelliklerin ise nesilden nesile geçerken elimine edilmesini basit formda temel alır (Meriç, 2004: 51). GA Amerikalı psikolog ve bilgisayar bilim adamı olan Holland (1975) tarafından teori haline getirilmiş ve bu teoride problemlerin çözümünde sadece optimizasyon yaklaşımını değil aynı zamanda biyoloji süreçlerini de kullanmıştır (Affenzeller vd., 2009: 1).

Holland, canlılardaki evrimden ve değişimden etkilenerek, bu genetik süreci makine ortamına aktarmıştır. Bu makine çalışmaları ile tek bir mekanik olgunun

öğrenme yeteneğini geliştirmek yerine, çok sayıdaki benzer yapıların “çiftleşme, çoğalma, değişim” gibi genetik süreçlerin sonucunda üstün yeni bireylerin elde edilebileceğini gösteren çalışmasından çıkan sonuçların yayınlanmasından sonra bu yöntemin adı “Genetik Algoritmalar” olarak adlandırılmıştır (Karasoy ve Ballı, 2016).

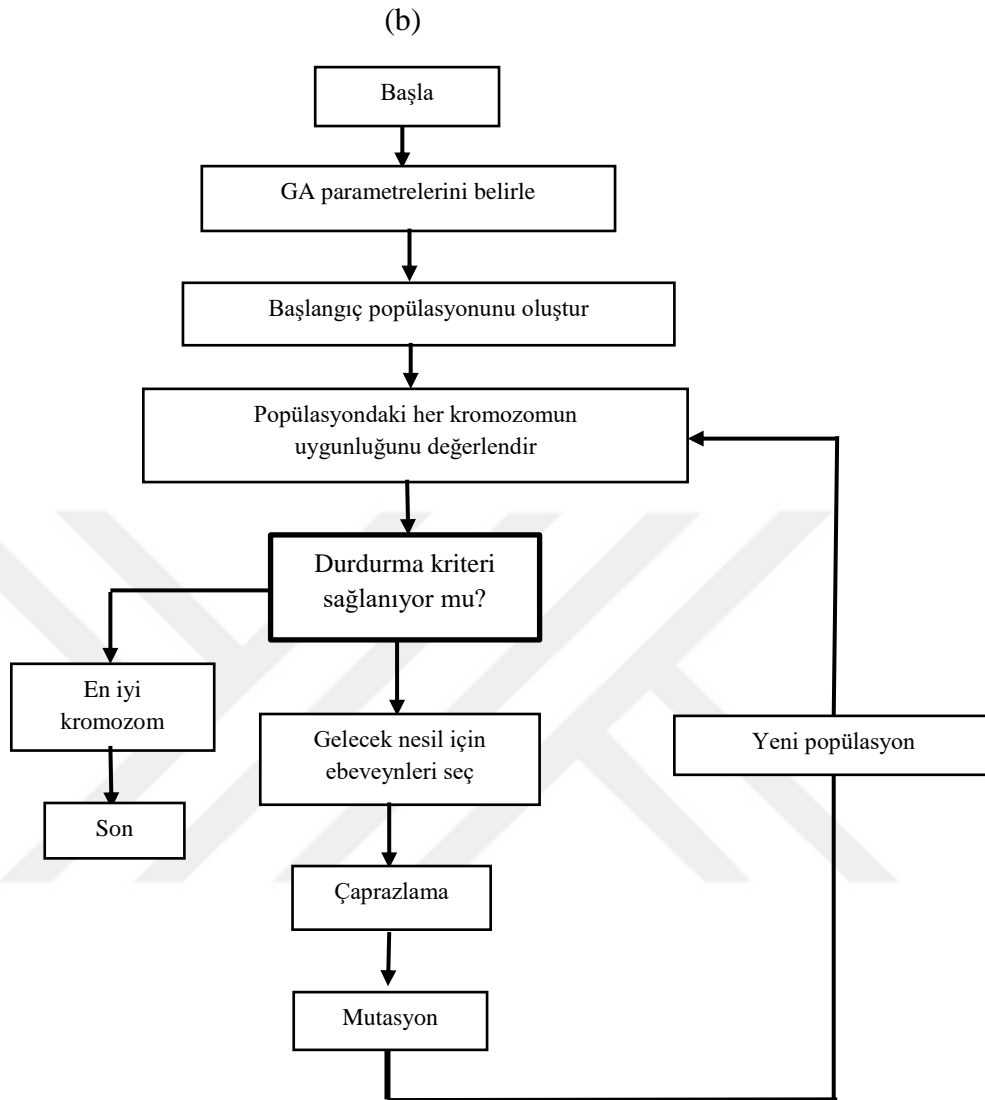
GA aslında popülasyon temelli optimizasyon yöntemidir. Popülasyonu oluşturan aday çözümlerin, kromozom, genotip ve gen gibi isimlerle ifade edilen değerler evrimsel tabanlı süreçler ile daha iyi denebilecek sonuçları temsil eden çözüm adaylarına dönüşerek evrimleşmesidir. Bu evrimleşme süreci ve işlemleri kabul edilebilir bir uygunluk değerine erişinceye kadar sürdürülür. Bu kabul edilebilirlik daha önceden belirlenen kriterler ya da değerler olabilir. Genel kural olmamakla beraber, genellikle aday çözümler 0 (sıfır) ve 1 (bir) lerden oluşan katarlar şeklinde belirtilir. Bazen bu durum problemin tipine göre farklılaşır. GA, daha önce bahsedildiği gibi aday çözümlerinden ve uygunluk fonksiyonundan meydana gelir. Aday çözümler yani kromozomlar, temsil ettiği çözüme ait değerlere sahip değişkenleri tutan katarlardır. Aday çözümlerin kalitesini ölçen fonksiyonlar ise uygunluk fonksiyonlarıdır (Kevran, 2009: 9).

2.2.3.1. Genetik algoritmaların çalışma prensibi

GA'nın sözde kodu Şekil 2.12 (a)'da gösterilirken GA adımları ise Şekil 2.12 (b)'de gösterilmektedir.

(a)

- | |
|---|
| <p>1- Başlangıç popülasyonu oluştur</p> <p>2- Uygunluk değerlerini hesapla</p> <p>3- En iyi uygunluğa sahip bireyleri seç</p> <p>4- Çaprazlama ve mutasyon adımlarını uygula</p> <p>5- Yeni bireylerin uygunluğunu hesapla</p> <p>6- İterasyon sayısına ulaşıldı ise işlemi bitir, değilse 3. adıma dön</p> |
|---|




Şekil 2.12. a) Genetik Algoritma Pseudocode (Baygın ve Zeren, 2015). b) Genetik Algoritma Akış Diyagramı (Pulat ve Deveci, 2016)

Şekil 2.12 (a) ve Şekil 2.12 (b) görüldüğü üzere ilk adım, çözümlerden başlangıç bireylerinin yani kromozomlarının üretilmesi adımıdır. Bu kromozomların topluluğuna popülasyon denilmektedir. Birinci adımda oluşturulan bireylerin, uygunluk değerlerinin, uygunluk fonksiyonuna göre hesaplanması ikinci adımda yapılmaktadır. Uygunluk fonksiyonu esas alınarak çaprazlanacak kromozomlar seçilir. Sonraki adımda yerel minimuma takılmamak için mutasyon işlemi uygulanmaktadır. Yeni oluşan nesiller ile birlikte uygunluk değerleri tekrar hesaplanma işlemine tabi tutulmaktadır. Eski kalan kötü kromozomlar ile yenileri yer

değiştirerek popülasyonun belirli bir sayıda tutulması sağlanmaktadır. Bu süreçler yeni bir nesil sayısına ulaşıncaya kadar devam etmektedir. Uygun sonlandırma değerine ulaşıldıktan sonra en uygun kromozom çözüm olarak kabul edilmektedir (Karasoy ve Ballı, 2016).

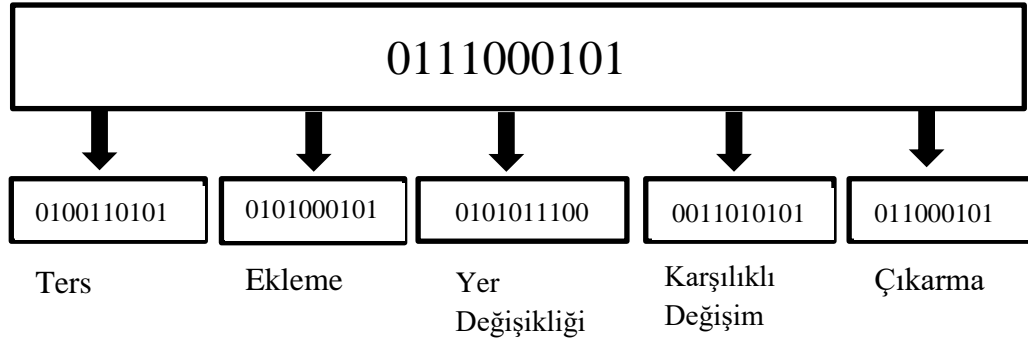
GA ile problemlerin çözüme ulaştırılmasında istenilen sonuçları üretecek özelliklerin kalıtım ile başlangıç çözümlerinden elde edilen yeni çözümlere onlardan da daha sonraki çözümlere aktarıldığı kabul edilmektedir. Yukarıda bahsedilen GA adımları özetle aşağıdaki gibi tanımlanabilir:

- Kromozom ve Gen: GA'dan çözmelerini istediğimiz N adet çözümden her birini göstermektedir. GA'dan bu N adet çözüm içinden en iyisini bulması istenmektedir. Kromozomlar ise bu çözümleri göstermektedir. Bir kromozomun elemanlarından her birisi çözümün bir özelliğini göstermektedir. Buna gen denilmektedir (Öztemel, 2016: 17).
- Çözüm havuzu: Problemin en iyi çözümünü aramak için kullanılan başlangıç çözüm kümesidir (Öztemel, 2016: 17).
- Çaprazlama: Kromozomların bulunduğu eşleme havuzundan iki adet kromozom seçilir. Seçilen kromozomlardan bir ve birden fazla yeni nesil meydana getirme hadisesine çaprazlama denir. En yaygın kullanım, iki kromozomdan iki yeni nesil elde edilmesidir. En başta kromozomun ilk biti ile son biti arasında çaprazlama noktası seçilir. Bu seçim rastgele olmaktadır. Birinci kromozomun çaprazlama noktasının solundaki bitlerin hepsi ikinci kromozoma geçerken, benzer şekilde ikinci kromozomun çaprazlama noktasının solundaki bitler de birinci kromozoma geçer. Sonuçta oluşan yeni bireyler, her iki kromozomun karakterlerini ihtiva etmektedir. Aşağıda örnek bir çaprazlama gösterilmektedir (Çunkaş, 2006: 22):

Kromozom1= 00100110011 101	Nesil1= 01010110000 101
<hr style="width: 50%; margin: 0 auto;"/>	
	Yer değişecek
Kromozom2= 01010110000 100	Nesil2= 00100110011 100

- Mutasyon: Kromozom üzerindeki DNA dizilerinin yerlerinin değiştirilmesi ile belirli mutasyon oranına göre değişiklikler yapılmasıdır

(Bolat vd., 2004: 266). GA yer deęiřtirme, rasgele seilen genlerin deęerinin “0” ise “1” deęerini alması “1” ise “0” deęerini alması biiminde iřleme tabi tutulur (Meri, 2004: 60).



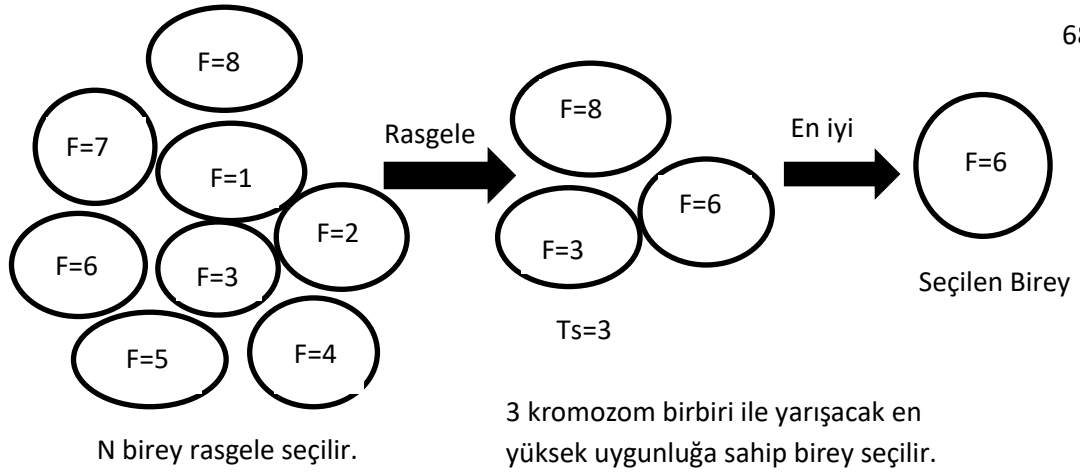
řekil 2.13. Mutasyon Yöntemleri (Bolat vd., 2004)

Kromozomların deęiřime uğraması řekil 2.13’te gösterildięi gibi ařaęıdaki řekillerde olabilir (řeker, 2009):

- Ters evirme (Inversion): Seilen bir kromozomun deęerinin tersine döndürülmesidir.
- Ekleme (Insertion): Gen dizilimine yeni bir kromozom eklenmesi řeklinde olmaktadır.
- ıkarma (Displacement): Dizilimden bir kromozomun eksilmesi ile gerekleřmektedir.
- Yer Deęiřiklięi (Reciprocal Exchange, Swap): Kromozomlardan birisinin dizilimdeki yeri deęiřmektedir.
- Karřılıklı Deęiřim: Rastgele seilen iki genin yerlerinin deęiřtirilmesidir.
- Uygunluk Fonksiyonu: GA’larda bireylerin uygun olup olmadıklarının ölçülebilmeleri için problemin yapısına göre bir uygunluk fonksiyonu kullanmaları gerekmektedir (Gözütok ve Özdemir, 2004: 127). Genetik algoritmaların her bir iterasyonunda, yığındaki dizilerin uygunluk deęerlerinin hesaplanması iřlevini uygunluk fonksiyonu gerekleřtirmektedir. Uygunluk deęeri, yığından hangi bireylerin bir sonraki yığının elde edilmesinde kullanılacağına tespitinde kullanılmaktadır. GA’larda uygunluk fonksiyonu, eniyileme problemindeki amaç

fonksiyonuna eş değerdir. GA başarılı olması için uygunluk fonksiyonun doğru tespit edilmesi gerekmektedir. Doğru tespit edilmemiş uygunluk fonksiyonu, çalışma zamanını fazlasıyla uzatabileceği gibi bazı durumlarda çözüme ulaşamama sorununa da sebebiyet verebilmektedir (Zeyveli, 2007: 3). Uygunluk fonksiyonu problemden probleme farklılık göstermektedir (Kaya ve İnce, 2011: 116).

- Yeniden Üretim: Çözüm havuzundaki kromozomlar çaprazlama ve mutasyon ile üretilen yeni kromozomlar sebebiyle çoğalmaktadır. Bunların arasından yüksek uygunluk değerine sahip kromozomlar seçilerek diğerleri atılmaktadır (Öztemel, 2016: 18). Seçim işlem süreci kromozomların tespit edilen uygunluk değerleri esas alınarak yapılmaktadır. Böylelikle daha yüksek uygunluk değerine sahip çözümler temsil edilmektedir. Seçme işlemindeki gaye iyi nesilleri seçmektir. Seçim işlemi popülasyon içinde uygunluk değeri düşük olan kromozomları eleyip, elenenlerin yerine yüksek uygunluk değerine sahip kromozomların birkaç adet kopyasını alarak tamamlanmaktadır. Böylelikle aday çözümlerden en güçlüsünün hayatta kalması sağlanmış olmaktadır (Kılıç Topal, 2015: 23). Yeniden üretim için farklı yöntemler uygulanmaktadır. Rus ruleti (Rus Tekerleği), elitizm, sıralı ve turnuva yöntemleri sık kullanılan yöntemlerdendir (İnceyol, 2014: 65). Rus ruleti yönteminde kromozomlar uygunluk fonksiyonu esas alınarak bir rulet etrafında gruplandırılmaktadır. Rulet üzerinde rasgele bir birey seçilmektedir. Kapladığı alan fazla olan kromozomun seçilme şansı fazladır. Fakat Rus ruleti seçiminde uygunluk çok fazla değişkende sıkıntı meydana getirebilecektir (Coşkun ve Arıcı, 2006: 259). Diğer kullanılan bir yöntem Şekil 2.14'de gösterilen turnuva yöntemidir.



Şekil 2.14. Turnuva Yöntemi ile Seçim (Pulat ve Deveci, 2016)

Şekil 2.14’de görüldüğü üzere turnuva yöntemi ile seçimde n kromozom popülasyonundan rasgele seçilmektedir. Popülasyondan seçilen kromozomlar birbirleriyle yarışa girmektedirler. En yüksek uygunluğa sahip kromozom kazanır ve kazanan yeni nesil popülasyona dahil olmaktadır. Her turnuvada yarışacak birey sayısı turnuva boyutu şeklinde adlandırılmaktadır ve bu sayı genellikle üçtür (Pulat ve Deveci, 2016: 8).

2.2.3.2. Genetik algoritmaların güçlü ve zayıf yönleri

Genetik algoritmaların güçlü ve zayıf yönleri aşağıdaki gibi sıralanabilir:

2.2.3.2.1 Güçlü yönleri

Genetik algoritmaların güçlü yönleri şunlardır (Berry ve Linoff, 1997: 446):

- Çok güçlü optimizasyon tekniğidir.
- Yapay sinir ağları veya diğer veri madenciliği teknikleri ile uyumlu çalışabilmektedir.
- Genetik algoritmalar, çok çeşitli uygunluk fonksiyonları üzerinde çalışır ve diğer yollarla kolayca ele alınmayan birçok farklı problemi kodlamayı mümkün kılmaktadır.
- Tahmin ve sınıflandırma vakalarında başarılı sonuçlar vermektedir.

Yukarıdaki maddelere ek olarak genetik algoritmalar çözüm uzayının geniş, süreksiz ve karmaşık olduğu problem tiplerinde başarılı sonuçlar vermektedir (Emel ve Taşkın, 2002: 138).

2.2.3.2.2. Zayıf Yönleri

Genetik algoritmaların zayıf yönleri ve kısıtları aşağıdaki gibi sıralanabilir (Marczyk, 2004):

- Uygunluk fonksiyonları doğru seçilmezse probleme çözüm bulunamaz.
- Kullanılan dil önemlidir. Kodlama doğru yapılmazsa başarılı olunamaz.
- Popülasyon büyüklüğü yeterli değilse uygun çözüme ulaşılamaz.
- Problem uzayının özelliklerinden istenilen kadar yararlanamazlar.

Genetik algoritmaların diğer bir zayıf yönü de, makine öğrenmesi sırasında çok zaman almasıdır (Meriç, 2004: 80).

2.2.4. Yapay sinir ağları (YSA)

2.2.4.1. Yapay sinir ağı tanımları

Literatürde Yapay Sinir Ağları (YSA) ile ilgili birçok tanımlama mevcuttur. Tanımlardan bazıları aşağıdaki gibidir:

YSA, insan beyninden ilham alınarak geliştirilmiş, ağırlıklı bağlantılar aracılığıyla birbirine bağlanan ve kendi belleğine sahip işlem elemanlarından oluşan paralel ve dağıtılmış bilgi işleme yapılarıdır. YSA için biyolojik sinir ağlarının bilgisayar programlarıyla taklidinin yapılmasıdır denilebilir (Elmas, 2007: 23).

YSA, öğrenme metodu ile yeni bilgiler üretilmesi gibi yetenekleri herhangi bir yardım almadan otomatik olarak gerçekleştirmek amacıyla geliştirilen bilgisayar sistemleridir. İnsan beyninin fonksiyonel özelliklerine benzer şekilde, öğrenme, ilişkilendirme, sınıflandırma, genelleme, özellik belirleme ve optimizasyon gibi konularda YSA başarılı sonuçlar vermektedir (Öztemel, 2016: 29).

YSA, hem dağıtılmış hem de sayısal bilgileri işleyebilen, bilgi işlem yöntemi olarak paralel işlem kullanılabilen ve yalnızca sayılar üzerinde işlem yapabilen bilgisayar sistemleridir (Allahverdi, 2002: 169).

YSA, deneysel bilgiyi depolamak ve kullanıma hazır hale getirmek için doğal bir eğilime sahip basit işleme birimlerinden oluşan kitlesel olarak paralel dağıtılmış bir işlemcidir. Yapısı itibarıyla insan beynine iki açıdan benzemektedir (Haykin, 1999: 2):

- Bilgi, bir öğrenme süreci yoluyla çevresinden ağ tarafından edinilir.
- Sinaptik ağırlıklar olarak bilinen nöronlar arası bağlantı gücü, edinilen bilgiyi depolamak için kullanılır

YSA, tahmin, sınıflandırma ve kümeleme işlemlerinin problemlerin çözümlenmesinde kullanıldığı doğrusal olmayan modellerdir (Akcan ve Kartal, 2011: 32).

YSA, insan beyninin işlevlerinden ilham alınarak geliştirilmiş deneme yolu ile öğrenme ve genelleştirme yapabilen, geleceği tahmin edebilme yeteneği olan doğrusal olmayan makine öğrenmesidir (Hamzaçebi ve Kutay, 2004: 228).

YSA, biyolojik sinir ağlarıyla ortak belirli performans özelliklerine sahip bir bilgi işleme sistemidir. Yapay Sinir Ağları, insan bilişinin veya sinir biyolojisinin matematiksel modellerinin genellemeleri olarak geliştirilmiş sistemlerdir (Fausett, 1994: 3).

YSA, yönlendirilmiş bir grafikte temsil edilen dinamik bir sistemdir (Hecht-Nielsen, 1989).

YSA, insanoğlunun beyin sinir sisteminden esinlenerek geliştirilmiş, belli ağırlıklı bağlantılar aracılığıyla birbirine bağlanan işlem elemanlarından oluşan paralel bilgi işleme yapılarıdır. En önemli özelliği, deneyimlerden yararlanarak öğrenebilmesidir.


YSA, öğrenme ile yeni bilgiler türetilir, oluşturabilir ve yeni keşifler oluşturabilir. Bu özellikleri yardım almadan gerçekleştirme kapasitesine sahiptir. YSA, öğrenmenin yanında bilgileri analiz ederek, bilgiler arasında ilişkiler kurma yeteneğine de sahiptir (Uğur ve Kınacı, 2006: 345).

Başka bir tanımlamada YSA; çok sayıda elemandan oluşmuş matematiksel bir model olarak tanımlanmaktadır (Gallo vd., 2005: 4).


Sonuç olarak, “yapay” kelimesi çıkartıldığında nöral bir ağ, belirli bir tür doğrusal olmayan fonksiyondan başka bir şey olarak görülmez (Anthony ve Bartlett, 2009: 2).

2.2.4.2. Biyolojik sinir ağıları

Temel olarak, her bir nöron (Sinir Hücreleri), elektrokimyasal bir sinyali yayabilen özel bir hücredir. İnsan beyni farklı tiplerde yaklaşık 100 milyar nöron (sinir hücresi) içermektedir. Bu nöronlar (Şekil 2.15) dendritler vasıtasıyla diğer nöronlardan sinyalleri toplamaktadır. Nöron, binlerce dala bölünen ve aksonlar üzerinden elektrik akımını göndermektedir (Gorunescu, 2011: 192). Nöronlar tarafından alınan sinyaller eşik değerlerine eşit veya ondan daha yüksek olduğunda, akson aracılığıyla bir elektrik sinyali gönderir. Bu şekilde mesaj bir nörondan diğerine aktarılır. Nöral ağda, nöronlar veya işlem üniteleri, dendritlere karşılık gelen çeşitli giriş yollarına sahip olabilmektedir. Üniteler genellikle bu yolların ağırlıklı değerleri ile basit bir toplama ile birleştirilmektedir (Şekil 2.16). Ağırlıklı değer nörona geçirilir ve sigmoid fonksiyonu gibi eşik fonksiyonu ile değiştirilir. Değiştirilen değer direkt olarak bir sonraki nörona sunulmaktadır (Alavala, 2008: 121-122).



Şekil 2.15. Bir Biyolojik Nöronun Yapısı (<https://cs.stanford.edu>)

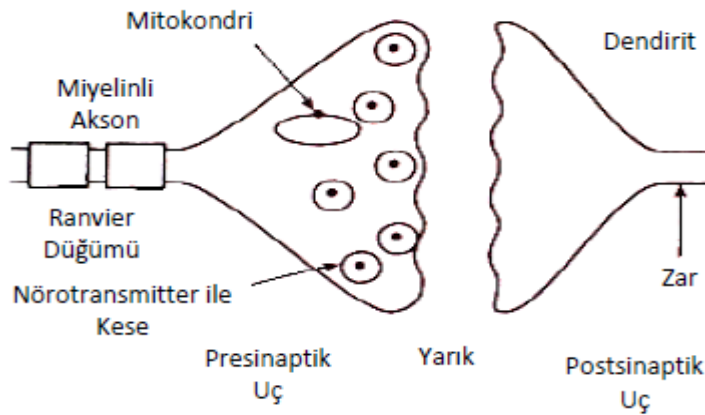


Şekil 2.16. Matematiksel Olarak Nöron Ağının Gösterimi (Alavala, 2008)

Şekil 2.15'te görüldüğü üzere dendritler oldukça karmaşık dentritik ağaçlarının içinde toplanmaktadır. Dendritik ağaçları, soma diye adlandırılan sinir hücresinin ana gövdesi ile bağlanmaktadır. Dış kısmı zar şeklinde olan hücrenin içi

intraselüler sıvı ve dış kısmı ise extraselüler sıvı ile kaplıdır. Nöronun zarı ile içindeki ve dışındaki öğeler, nöronun fonksiyonunda önemli bir yere sahiptir. Belirli bir seviyenin üstünde uyarıldığında nöron ateşlenir ve böylece akson elektriksel sinyal göndermektedir. Akson, diğer nöronların dendritleri ile bağlı olan aksonun bitişi ile son bulmaktadır. Bir nöronun aksonu ile başka nöronun dentiriti arasındaki bağlantı sinaps diye adlandırılmaktadır. Bir sinaps Şekil 2.17’de görüldüğü üzere presinaptik terminal, yarık veya sinaptik kesişim yeri ve postsinaptik terminalden oluşmaktadır. (Kartalopoulos, akt Akdağ, 2014 ss.43-44).

Bir sinir hücresinin çekirdeği “soma” olarak adlandırılmakta olup vücudumuzda yer alan diğer hücrelerin çekirdeklerinden farklıdır. Soma diğer hücre çekirdeklerinin yaptığı göreve ek olarak, sinir hücresinin bilgi işleme yeteneğini oluşturan bir görev daha yerine getirmektedir. Soma, dendritlerden gelen elektriksel uyarının yeterli düzeyde olup olmadığını kontrol etmektedir. Eğer bir sinir hücresine gelen elektriksel uyarılar belli bir eşiği aşarsa, soma, akson üzerinde bir elektrik akımı üreterek, kendisiyle sinapstik bağ oluşturan diğer sinir hücrelerini uyarmaktadır. Bir hücre akson üzerinde elektrik uyarısı ürettiğinde sinir hücresi tetiklenmiş kabul edilmektedir. Eğer uyarı düzeyi yeterli değilse hiç akım üretmez ve diğer hücreleri uyarmamış olur. En basit ifadeyle öğrenmenin fizyolojik şekli, bir sinir hücresinin uyarı üreteceği eşik değerinin değişmesinden ibarettir denilebilir (Yıldız, 2009: 11).



Şekil 2.17. Sinaps Görünümü (Akdağ, 2014)

Şekil 2.17’de görünen Sinaps, bir nöronun diğerine bağlantı noktasıdır. Bununla birlikte, sinapsların sinir sinyallerinin sinir sistemi boyunca yayılacağı yönleri belirlediğini vurgulamak önemlidir. Bazı sinapslar, bir nöronun diğerine kolaylıkla sinyal gönderir, diğerleri ise sinyalleri yalnızca zorlukla iletilmektedir. Ayrıca, sinir sistemindeki diğer alanlardan gelen kolaylaştırıcı ve inhibitör sinyaller sinaptik iletimi kontrol edebilir, bazen iletim için sinapsları açabilir ve diğer zamanlarda onları kapatabilmektedir. Buna ek olarak, bazı postsinaptik nöronlar çok sayıda çıkış uyarı etkisi ile yanıt vermekte ve diğerleri sadece birkaçıyla yanıt vermektedir. Böylece, sinapslar, güçlü sinyallerin geçmesine izin verirken genellikle zayıf sinyalleri bloke eden seçici bir eylem gerçekleştirir, ancak diğer zamanlarda bazı zayıf sinyalleri seçer ve güçlendirir ve genellikle bu sinyalleri yalnızca bir yön yerine birçok yöne kanalize eder (Guyton ve Hall, 2006: 557).

Yapay sinir ağının biyolojik sinir ağından esinlenerek geliştirildiği konusu daha önce belirtilmişti. Biyolojik sinir ağındaki bazı bölgeler yapay sinir ağı fonksiyonlarına benzemektedir. Tablo 2.3’de yapay sinir ağı ile biyolojik sinir ağı arasındaki benzerlik açıklanmıştır.

Tablo 2.3. Biyolojik Sinir Ağı ile YSA’nın Karşılaştırılması (Elmas, 2007)

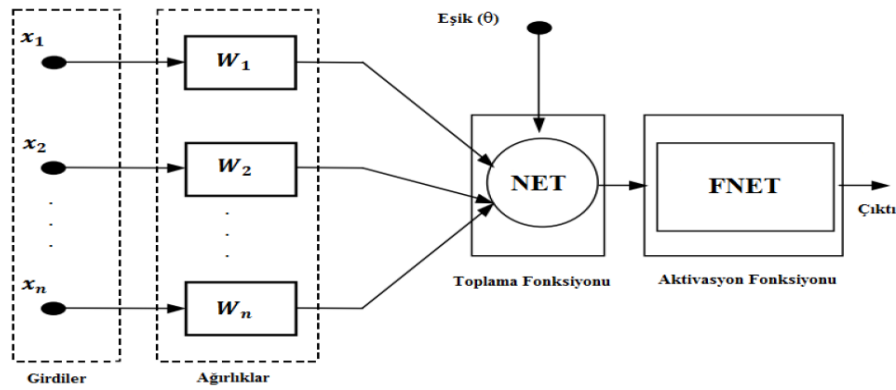
Biyolojik Sinir Ağı	Yapay Sinir Ağı
Sinir Sistemi	Sinirsel Hesaplama Sistemi
Sinir	Düğüm
Sinaps	Sinirler Arasındaki Bağlantı Ağırlıkları
Dendrit	Toplama İşlevi
Hücre Gövdesi	Etkinlik İşlevi
Akson	Sinir Çıkışı

Özetle insan sinir sistemi sinir hücrelerinden oluşmaktadır. İnsanın beyininde 100 milyar sinir hücresinin yaklaşık 1 katrilyon bağlayıcısı vardır. Her sinir hücresi insan vücudundaki hücrelerle birlikte ortak özellikler göstermektedir. Sinir hücrelerinin görevi sinyal alma, işlem yapma ve elektrokimyasal sinyallerin sinir ağları içinde iletimini sağlamaktır. Daha önce belirtildiği gibi dentritler, sinyalleri sinaps diye adlandırılan birleşme noktasından almaktadır. Sinapsların alıcı kısmı olan bölümleri ile hücre vücudu iletişim halindedir. Burada toplandıkları bazı girdiler hücreyi etkileme gayreti göstermektedir. Hücre, vücudu içinde kümülatif uyarma

eşliğini aştığı durumda uyarılır ve aksondan diğer sinir hücrelerine sinyal göndermektedir. Bu basit işlevsel çıkış beraberinde fazlaca karmaşıklığı kapsamaktadır. Fakat YSA bu tür basit karakteristikleri kendisine model almaktadır (G. Akkaya, 2007: 196).

2.2.4.3. Yapay sinir hücreleri

Yapay sinir hücreleri, YSA'nın işleyişinde önemli bir yer tutan en küçük bilgi işlem birimidir. YSA hücre modeli; girdiler, ağırlıklar, toplama fonksiyonu, aktivasyon fonksiyonu ve çıktılar bileşenlerinden oluşmaktadır (Özkan, 2011: 188). Şekil 2.18'de gösterilen bu beş bileşen aşağıda açıklanmıştır:



Şekil 2.18. Yapay Sinir Hücresinin Yapısı (Kızılkaya, 2017)

Girdiler: Girdiler (X_1, X_2, \dots, X_n) dış ortamdan aldığı bilgiyi sinire iletir. Girdiler, kendinden önceki sinirlerden veya dış dünyadan sinir ağına gelebilmektedir. Bir sinir gelişigüzel birçok girdiyi alabilmektedir (Elmas, 2007: 31).

Ağırlıklar: Ağırlıklar (W_1, W_2, \dots, W_n) girdi kümesi veya kendinden önceki bir tabakadaki başka bir işlem elemanının bu işlem elemanı üzerindeki etkisini ifade eden katsayılardır. Şekil 2.18'de girdinin hücre üzerindeki etkisi görülmektedir (Günoğlu vd., 2011: 154). Bir ağırlığın değerinin büyük olması, o girişin yapay sinire güçlü bağlandığını ya da önem teşkil ettiğini göstermektedir. Ters durumda, yani ağırlık değerinin küçük olması zayıf bağlandığını ya da önem teşkil etmediğini göstermektedir (Özkan, 2011: 188). Başka bir ifade ile ağırlıklar, elemanlar arasındaki bağlantıların, güçlü yönleri temsil eder, bu bağlantıların yönlerinin bilgi

akışını kurmaktadır. Daha spesifik olarak düğümlerin ve ağı giriş ve çıkışlarını tanımlamaktadırlar (Fine, 1999: 2).

Toplama Fonksiyonu: Bir hücreye iletilen net girdiyi hesap eder. Bu hesaplama için farklı fonksiyon çeşitleri kullanılmaktadır. En sık olanı ağırlıklı toplamı bulmaktır. Burada gelen girdi değeri ile kendi ağırlığı çarpılarak toplamır (Civelekoğlu, 2006: 36). Bunun sonucunda ağa gelen net girdi bulunur.

$NET = \sum_1^n X_i W_i$ Bu denklemde X girdileri, W ise ağırlıkları ifade ederken n ise bir hücreye gelen toplam girdi sayısını göstermektedir. Literatürde toplama fonksiyonu olarak Tablo 2.4’de görüldüğü üzere çeşitli fonksiyonlar kullanılmaktadır.

Tablo 2.4. Toplama Fonksiyonları (Çayıroğlu, 2015)

Toplam; $Net = \sum_{i=1}^N X_i * W_i$	Ağırlık değerleri girdiler ile çarpılır ve bulunan değerler birbiriyle toplanarak Net girdi hesaplanır.
Çarpım; $Net = \prod_{i=1}^N X_i * W_i$	Ağırlık değerleri girdiler ile çarpılır ve daha sonra bulunan değerler birbiriyle çarpılarak Net girdi hesaplanır.
Maksimum; $Net = \text{Max}(X_i * W_i)$	n adet girdi içinden ağırlıklar girdilerle çarpıldıktan sonra içlerinden en büyüğü Net girdi olarak kabul edilir.
Minimum; $Net = \text{Min}(X_i * W_i)$	n adet girdi içinden ağırlıklar girdilerle çarpıldıktan sonra içlerinden en küçüğü Net girdi olarak kabul edilir.
Çoğunluk; $Net = \sum_{i=1}^N \text{Sgn}(X_i * W_i)$	n adet girdi içinden girdilerle ağırlıklar çarpıldıktan sonra pozitif ile negatif olanların sayısı bulunur. Büyük olan sayı hücrenin net girdisi olarak kabul edilir.
Kümülatif Toplam; $Net = \text{Net (Eski)} + \sum_{i=1}^N X_i * W_i$	Hücreye gelen bilgiler ağırlıklı olarak toplanır. Daha sonra hücreye gelen bilgilere yeni hesaplanan girdi değerleri ile eklenerek hücrenin net girdisi hesaplanır.

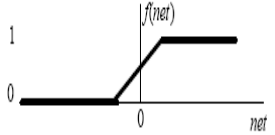
Tablo 2.4’de görüldüğü üzere, bazı durumlarda gelen girdilerin değeri dikkate alınırken bazı durumlarda ise sayı önem teşkil etmektedir. Kullanılan bir YSA’da en uygun toplama fonksiyonunu (işlevi) tespit etmek için bulunmuş bir formül yoktur. Deneme yanılma metodu ile toplama fonksiyonu (işlevi) tespit edilmektedir. Bir YSA’da bulunan girdi elemanlarının tamamının aynı toplama işlevine sahip olmalarına gerek yoktur. Her girdi elemanı bağımsız olarak farklı bir

toplama işlevine sahip olabilecekleri gibi hepsi aynı girdi elemanına sahip olabilmektedir (Öztemel, 2016: 49).

Aktivasyon Fonksiyonu: Bu işlev hücreye iletilen net girdiyi işleyerek hücrenin bu girdiye karşılık üretecek fonksiyonu belirler. Aktivasyon fonksiyonu olarak genellikle doğrusal olmayan bir fonksiyon seçilir. YSA'nın doğrusal olmama özelliği, aktivasyon fonksiyonunun doğrusal olmamasından kaynaklanmaktadır. Aktivasyon fonksiyonu seçilirken, fonksiyonun türevinin kolay hesaplanabilir olması dikkat edilmesi gereken hususlardandır. Geri beslemeli ağlarda aktivasyon fonksiyonunun türevi de kullanılmaktadır. Seçilecek aktivasyon fonksiyonunun türevinin zor hesaplanabilir olması durumunda hesaplamada yavaşlama olacaktır. Literatürde en sık kullanılan çok katmanlı algılayıcı modellerinde genellikle sigmoid fonksiyonu kullanılmaktadır (Çayıroğlu, 2015: 5). Tablo 2.5'de literatürde kullanılan aktivasyon fonksiyonları gösterilmiştir.

Tablo 2.5. Aktivasyon Fonksiyonları (Çayıroğlu, 2015)


Aktivasyon Fonksiyonu	Formül	Grafik
Lineer Fonksiyon	$F(\text{NET}) = A * \text{NET}$ $A = \text{Sabit Bir Sayı}$	
Step Fonksiyonu	$F(\text{NET}) = \begin{cases} 1 & \text{eğer } \text{NET} \geq \text{Eşik d.} \\ 0 & \text{eğer } \text{NET} < \text{Eşik d.} \end{cases}$	
Sigmoid Fonksiyonu	$F(\text{NET}) = \frac{1}{1 + e^{-\text{NET}}}$	
Hiperbolik Tanjant Fonksiyonu	$F(\text{NET}) = \frac{e^{\text{NET}} + e^{-\text{NET}}}{e^{\text{NET}} - e^{-\text{NET}}}$	

Eşik Değer Fonksiyonu	$F(\text{NET}) = \begin{cases} 0 & \text{eğer } \text{NET} \leq 0 \\ \text{NET} & \text{eğer } 0 < \text{NET} < 1 \\ 1 & \text{eğer } \text{NET} \geq 1 \end{cases}$	
------------------------------	--	---

Aktivasyon fonksiyonlarından lineer fonksiyon, gelen girdiler olduğu gibi hücrenin çıktısı olarak kabul edilmektedir. Step fonksiyonunda, gelen NET girdi değerinin belirlenen bir eşik değerinin altında veya üstünde olması durumuna göre hücrenin çıktısı 1 veya 0 alınmaktadır. Eşik değer fonksiyon, gelen bilgilerin 0 veya 1'den büyük veya küçük olmasına göre 0 ve 1 arasında bir değer alır. Hiperbolik tanjant fonksiyonu, gelen NET girdi değerinin tanjant fonksiyonundan geçirilmesi ile hesaplanmaktadır (Öztemel, 2016: 51).

2.2.4.4. Yapay sinir ağının yapısı

Bir YSA yapay sinir hücrelerinin birleşmesinden oluşmaktadır. Bu ağdaki hücreler birbirleri ile iletişim halindedir. Bir yapay sinir hücresinin çıktısı başka hücreler için girdidir. Şekil 2.19'da görüldüğü üzere, yapay sinir ağında hücreler katman halinde sıralanmaktadır.



Şekil 2.19. Yapay Sinir Ağı Modeli (Ağyar, 2015)

Şekil 2.19'da görüldüğü üzere YSA'da dışarıdan girdilerin ağa alınmasını sağlayan hücrelerin bulunduğu ilk katman girdi katmanıdır. İşlenen verilerin ağın

dışına gönderilmesi görevini üstlenen hücrelerin bulunduğu katman ise çıktı katmanıdır ve bu son katmandır. Bu iki katman arasında kalan katman/katmanlar ise gizli katman ya da katmanlar olarak tanımlanmaktadır. Bir YSA'da katman sayısından bahsedildiğinde bu gizli katmanları ifade etmektedir. Bu ifadeye girdi ve çıkış katmanlarının sayısı eklenmez. Örneğin üç katmanlı bir YSA belirtildiğinde bu aslında üç gizli katmanı ve ayrıca girdi ve çıktı katmanlarının beraberinde yer olduğu bir yapay sinir ağıdır. Bir YSA'nın katmanlarının ve hücrelerin dizilişi, bir biriyle bağlantı şekilleri gibi tanımlamalar, YSA'nın mimarisi şeklinde tanımlanmaktadır (Yıldız, 2009: 60).

2.2.4.5. Yapay sinir ağlarında öğrenme

İnsanın biyolojik yapısındaki öğrenme süreci, nöronların arasındaki sinaptik bağlantıların düzenlenmesi ile gerçekleşmektedir. İnsan doğumdan itibaren yaşayarak öğrenme süreci ve faaliyeti içerisine girmektedir. Bu devam eden süreçte beyin devam eden bir gelişme göstermektedir. Hayatın işleyişi süresince, tecrübe eylemlerinin sinaptik bağlantılar üzerindeki etkisi ile bağlantılar ayarlanmaktadır. Bazen yeni bağlantılar da oluşması mümkün olmaktadır. Bahsedilen eylemler neticesinde öğrenme gerçekleşmektedir. Bu durum YSA'lar için de aynıdır. Öğrenme, YSA'ları eğitme yoluna giderek ve örnekler kullanılarak olmaktadır. Başka bir ifade ile gerçekleşme, girdi-çıkış verilerinin işlenmesi ile yani eğitme algoritmasının bu verileri kullanarak bağlantıdaki ağırlıklarını bir yakınsama sağlanana kadar, tekrar tekrar ayarlanmasıyla olmaktadır (Yurtoglu, 2005: 5).

Öğrenme yeteneği YSA'nın en önemli karakteristik özelliğidir. YSA'nın uyarılması ile ağırlıklarını belli bir şekilde ayarlaması süreci öğrenmeyi tanımlar (Haykin, 1999). İlk etapta bu ağırlık değerleri rastgele atanır. YSA, kendilerine gösterilen örnekler doğrultusunda ağırlık değerlerini günceller. Amaç, ağa tanıtılan örnekler için doğru çıktılar üretecek ağırlık değerlerini bulmaktır. Ağın doğru ağırlık değerlerine ulaşması, örneklerin temsil ettiği olaylar hakkında genellemeler yapabilme yeteneği elde etmesi demektir. YSA'nın mevcut örneklerden ilgili bilgileri çıkararak bilinmeyen örnekler hakkında çıkarım yapma diğer ifade ile genelleme yapma yeteneğini elde etmesine "ağın öğrenmesi" denilmektedir (Akdağ, 2014: 50). Bu tanımlama ile aşağıdaki sonuçları çıkarabilmek mümkündür (Hamzaçebi, 2011: 21):

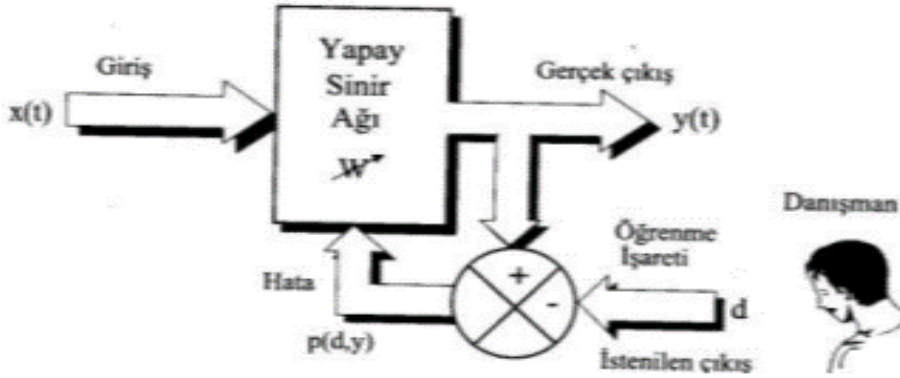
- YSA yer aldığı çevre tarafından uyarılmaktadır.
- Bu uyarıların neticesinde, ağırlıklarında değişiklikler olmaktadır. Bu değişiklik daha önceden belirlenmiş kurallar çerçevesinde gerçekleşmektedir.
- YSA iç yapısında meydana gelen değişiklikler neticesinde çevresine bir çıktı sunmaktadır.

Ağın değerlerinin süreç içinde yenilenmesi belli birtakım kurallar çerçevesinde yürütülmektedir. Bu kurallara öğrenme kuralları denilmektedir. Kullanılan öğrenme stratejisine göre değişik öğrenme kuralları geliştirilmiştir. YSA'larda öğrenme iki aşamada olmaktadır. İlk aşamada ağa gösterilen örnek için ağın üreteceği çıktı belirlenmektedir. Bu çıktı değerinin doğruluk derecesine göre ikinci aşamada ağın bağlantılarının sahip olduğu ağırlıklar değiştirilmektedir. Ağın eğitimi bittikten sonra öğrenme performansının ölçümü eylemine ise “ağın test edilmesi” denilmektedir. Test aşamasında ağın öğrenme aşamasında gösterilen örneklerden farklı örnekler kullanılır. Test aşamasında ağın ağırlık değerleri değiştirilmez. Test örnekleri ağa tanıtılır ve eğitim sırasında belirtilen bağlantı ağırlıklarını kullanarak hiç görmediği bu örneklerle çıktılar üretmektedir. Çıkan çıktıların doğruluk değerleri ağın öğrenmesi hakkında bize bilgiler vermektedir. Çıkan sonuçlar ne kadar iyi olursa eğitim performansı da o kadar iyi demektir. Eğitim aşamasında kullanılan örnek setine eğitim seti, test aşamasında kullanılan sete ise test seti denilmektedir. YSA'nın belirtilen şekilde bilinen örneklerden belirli bilgileri çıkartarak bilinmeyen örnekler hakkında yorum yapabilme yeteneğine “Adaptif Öğrenme” adı verilir (Öztemel, 2016: 56). Yapay sinir ağlarının öğrenmeleri için genellikle iki yaklaşım bulunmaktadır; danışmanlı (supervised) ve danışmansız (unsupervised) öğrenme (Ataseven, 2013: 104).

2.2.4.5.1 Danışmalı öğrenme

Danışmalı öğrenmede, YSA kullanılmadan önce eğitime tabi tutulmaktadır. Yapay sinir ağına giriş ve çıkış bilgilerinin sunulması eğitime işlemidir. Şekil 2.20'de gösterildiği üzere, giriş ve çıkış bilgileri eğitime kümesi olarak adlandırılmaktadır. Her bir giriş kümesi için çıkış kümesi ağa tanıtılmaktadır. Bazı uygulamalarda ağa gerçek veriler uygulanmak zorundadır. Bu tip durumlarda eğitim süresi oldukça vakit alabilmektedir. YSA, girişler için istenen istatistiksel doğruluğu bulduğu zaman

eđitim iŖi tamamlanmıŖ olmaktadır. Bazı durumlarda sistemin önemli olan özellikleri ve iliŖkileri öğrenmesi gerekebilmektedir. Bu tip durumlarda eđitim kümesinin ihtiyaç duyulan tüm bilgileri içermesi gerekmektedir. Ađın sadece bir çeŖit örnek ile eđitilmesi durumunda, bir olay için çok hassas olan bütün ađırlıklar kümesi, daha sonraki olayda yeterli ve dođru çözümleri verememektedir. Bir ađın başarısı ancak giriŖ ve çıkıŖ bilgilerinin dođru kodlanması ile mümkündür. YSA sadece sayısal giriŖ bilgileri ile çalıŖtıđı için ham veriler sayıŖallaŖtırılmalıdır. DanıŖmalđ öğrenmede giriŖ ve çıkıŖ çiftlerinden oluŖan eđitim bilgileri vardır. Ađ, giriŖte sunulan bilgilere göre ürettiđi çıkıŖ deđerini istenen deđerlerle karŖılaŖtırarak ađırlıkların deđiŖtirilmesinde kullanılacak bilgiyi elde etmektedir. Girilen deđerle istenen deđer arasındaki fark hata deđer olarak daha önceden belirlenen deđerden küçük oluncaya kadar eđitime devam etmektedir. Hata deđer istenilen deđerin altına düŖtüđünde tüm ađırlıklar sabitlenerek eđitim iŖlemi sonlandırılmaktadır (Elmas, 2007: 88).




Ŗekil 2.20. DanıŖmalđ Öğrenme Yapısı (BeŖdok ve Erler, 2003)

2.2.4.5.2 DanıŖmansız öğrenme

İstenilen çıkıtlar ađa tanıtılmıyorsa, bu tip öğrenme modeli danıŖmansız öğrenme olarak adlandırılmaktadır. Bu öğrenme modelinde, öğrenme algoritmaları geçmiŖ veri kümelerinin içinde saklı istatistiksel bilgilerin elde edilmesini amaçlamaktadır. DanıŖmansız öğrenmede girdiler aynı zamanda çıkıtları görevi görmektedir. Hem girdi hem de çıkıtları olan veriler arasındaki kural ve iliŖkilerin araŖtırılması ve en uygununun bulunması ađın eđitilmesi anlamına gelmektedir (Hamzaçebi, 2011: 22). DanıŖmansız öğrenmede, istenilen y çıkıŖları bilinmemektedir. Bu nedenle net bir hatayı ađın davranıŖını deđiŖtirmekle kullanmak

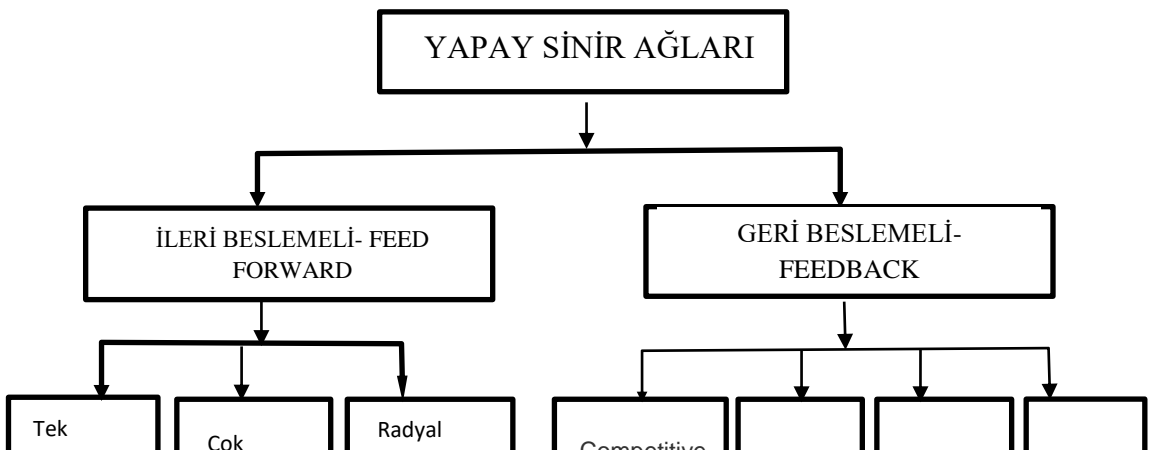
mümkün değildir. Cevabın doğruluğu veya yanlışlığı bilinmediği için öğrenme, girişlerin verdiği cevaplar gözlenerek başarıya ulaşılmaktadır. Gerçekte bu tip öğrenme metodunda da danışman vardır ama, danışman her öğrenme adımında işleyişe dahil olmamasına rağmen, amaçları ayarlamaktadır (Çelik, 2009: 93). Danışmansız öğrenmeye, Hebbian öğrenme, Grossberg öğrenme ve Kohonen'in öz örgütlemeli harita ağı örnek olarak verilebilmektedir. (Elmas, 2007: 137). Kohonen öğrenme kuralı, Kohonen (1982) tarafından biyolojik sistemdeki öğrenmeden esinlenerek geliştirilmiş bir kuraldır. Bu kural, işlem elemanlarının ağırlıklarını rekabete girerek ayarladıklarını söylemektedir. En uygun "y" çıktısına sahip işlem elmanı baskın elemandır ve sadece bu nöronun çıktı sağlaması söz konusu olmaktadır. Kendi kendine öğrenme olarak bilinen bu kural genellikle dağılımlar konusundaki çalışmalarda kullanılmaktadır (Yurtoglu, 2005: 101). Şekil 2.21'de danışmansız öğrenme şematik olarak gösterilmiştir.



Şekil 2.21. Danışmansız Öğrenme Yapısı (Elmas, 2007)

2.2.4.6. Yapay sinir ağı mimarileri

Yapay sinir ağı mimarileri, sinir hücreleri arasındaki bağlantıların yönlerine göre veya ağ içindeki işaretlerin akış yönlerine göre birbirinden ayrılmaktadır. Bunlar; ileri beslemeli (feed forward) ve geri beslemeli (feedback, recurrent) ağlardır (Ataseven, 2013: 103). Şekil 2.22'de yapay sinir ağı mimari yapısı gösterilmektedir.




Şekil 2.22. Yapay Sinir Ağı Mimarisi (Khare ve Nagendra, 2007)

Şekil 2.22’de görüldüğü üzere yapay sinir ağları ikiye ayrılmaktadır. İleri beslemeli (feed forward) ağlar üç, geri beslemeli (feedback, recurrent) ağlar da yapılarına göre dört gruba ayrılmıştır. İleri beslemeli ağlar; tek katmanlı, çok katmanlı ve radyal tabanlı ağlar şeklinde ayrılırken geri beslemeli ağlar ise; competitive makine öğrenme, kohonen (Self Organizing Maps-Özdüzenleyici Haritalar) ağları, hopfield ağları ve ART model şeklinde ayrılmıştır.

2.2.4.6.1. İleri beslemeli ağlar

İleri beslemeli YSA’da esas olarak üç katman bulunmaktadır. Bunlar; giriş, gizli ve çıkış katmanlarıdır. Giriş katmanı, YSA’da giren verileri tutan katmandır. Gizli katman, işlemlerin yapıldığı ve istenilen sonuca göre kendisini eğiten katman ya da katmanlardır. Son katman olan çıkış katmanı ise, çıkış değerlerini veren katmandır. Gizli katmanın (hidden layer) kaç katmandan oluşacağı incelenen problemin yapısına göre belirlenmektedir. Her gizli katmanda bir ya da daha fazla sinir hücresi bulunabilmektedir. İleri beslemeli YSA’da mevcut bulunan her katmanda ne kadar sinir hücresi olacağına karar verirken öncelikle giriş katmanında kaç sinir hücresi olacağına ağın girdisi olan verilerin sayısına göre karar verilir. Giriş katmanındaki her bir nöron (sinir hücresi), sonucu etkilemesi istenen değişkene karşılık gelmektedir. Çıkış katmanındaki uygulama da buna benzerdir. Çıkış bilgilerinin hangi biçimde gösterilmesi istendiğine karar verildikten sonra bu çıkışta bulunması istenen her değişken için bir sinir hücresi bulundurması gerekir. Bir sınıflandırma probleminde çıkış katmanında farklı sınıfların gösterilmesini sağlamaya yeterli miktarda nöron bulunması gereklidir (Şeker, 2008). Şekil 2.23’de bir ileri belemeli yapay sinir ağı modeli görülmektedir.



Şekil 2.23. İleri Beslemeli Yapay Sinir Ağı Mimarisi (Serhatlioğlu, ve Hardalaç, 2009)


Şekil 2.23’de görüldüğü üzere ağ, giriş katmanı, gizli katmanlar ve çıkış katmanından oluşmaktadır. Bilgi bir yönde ilerler ve bu ilerleme giriş katmanından çıkış katmanına doğru bir ilerlemedir. Giriş katmanlarının etkinliği, tek tek ağlarla beslenen verileri temsil etmektedir. Her giriş nöronu, sinir ağının çıkışı üzerinde bir etkisi olan bağımsız değişkenleri temsil etmektedir. Gizli katmanların faaliyetleri, giriş birimlerinin faaliyetleri ve giriş ile gizli birimler arasındaki bağlantılardaki ağırlıklar tarafından belirlenmektedir (Hanrahan, 2011: 17).

2.2.4.6.2. Geri beslemeli yapay sinir ağları

En genel formda bir geri beslemeli YSA bir dizi işlem ünitesinden oluşmakta, her birimin çıkışı aynı ünite de dahil olmak üzere diğer tüm birimlere giriş olarak beslenmektedir. İki üniteyi birbirine bağlayan her bir bağlantı ile bir ünitenin diğer birime giriş olarak beslediği çıkış miktarını belirleyen bir ağırlık ile ilişkilendirilmektedir. Genel bir geri beslemeli ağ herhangi bir yapıya sahip değildir ve dolayısıyla herhangi bir modeli tanıma görevini çözmek için yararlı olması muhtemel olmamaktadır (Yegnanarayana, 2005: 142).

Geri beslemeli YSA’larda, girdi katmanındaki verileri işleyen işlemci, ürettiği bilgiyi yeniden veri olarak başka bir işlemciye girdi olarak vermektedir ve ara katmanlardaki aktivasyon değerleri, sonraki katmanlara girdi olarak

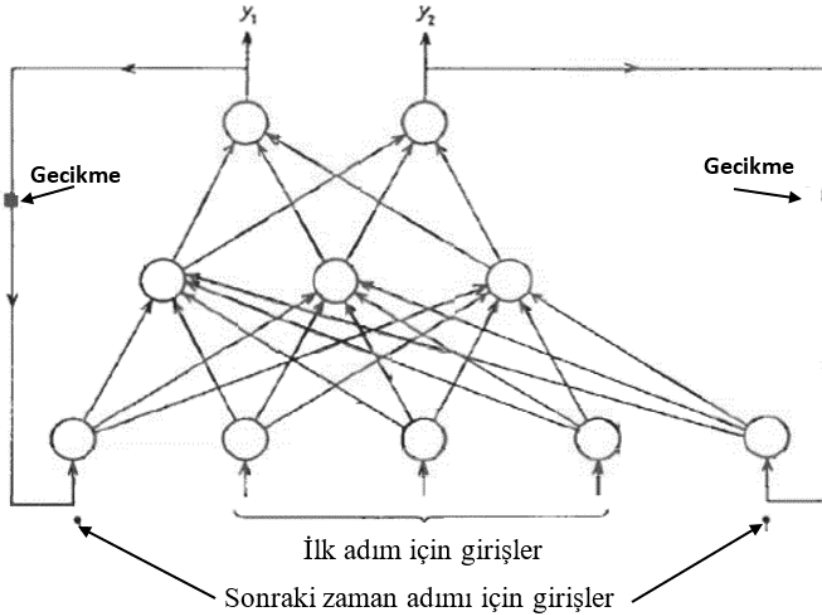
iletilmektedir. Geri besleme, tüm katmanlar arasındaki iletişime ortam oluşturacak biçimde şekillenebilmektedir. Geri beslemeli YSA'nın bu özelliği ile bağımsız değişkenlere ait veriler ileri ve geri bildirimli biçimde gerideki katmanlara iletilebilmektedir. Yani son olarak elde edilen çıktılar, daha önceki girişlerdeki işlenmiş bilgiyi de dinamik bir hafıza ile yansıtmaktadır. Daha öncede bahsedilen geri beslemeli ağların danışmalı öğrenme ile kullanılan en bilineni Hopfield ağlardır. Hopfield (1982) tarafından geliştirilen modelde, tek katmandan oluşturulan ağ içinde fazla sayıda nöron, birbirleri arasında geri beslemeli bilgi üreterek neticede bir çıktı oluşmasını sağlamaktadır. Hopfield ağlarının ileri beslemeli ağlardan ayırt eden özelliği, nöronların birbirleriyle bağlantı içinde olması ve nöronların kendi aralarındaki ağırlıkların sabitlenmesi olduğu görülmektedir. Bu ağ tipinde, zaman serilerinin veri oluşturduğu analizlerde kullanılmaktadır. Elman ve Jordan ağları da geri beslemeli ağlara örnek olarak verilebilir (Özün, 2011: 57-58). Tekrarlayan (zaman döngüsü) geri yayılma ağı Şekil 2.24'de açıklanmaktadır.



Şekil 2.24. Geri Beslemeli Ağ Yapısı (Graupe, 2007)

Gerçek besleme döngülerindeki gecikme elemanları (Şekil 2.24'deki D), zaman aşamaları arasında (genellikle tek iterasyonlara karşılık gelen dönemler) ayırıcıdır. İlk

devir sonunda, çıkışlar girişe geri beslenmektedir. Şekil 2.24'deki ağdaki, x_1 ve x_2 girişlerini, birinci dönemi (döngü) belirleyen bir tam dizinin (set) çeşitli zaman aşamalarında almaktadır. Ağırlıklar, geleneksel geri yayılım ağlarında olduğu gibi hesaplanır ve bu döngünün sonuna kadar ağırlıkların gerçek bir şekilde ayarlanmadığı bir döngünün tüm zaman adımlarında toplanmaktadır. Her zaman adımında, y_1 ve y_2 çıkışları, bir sonraki zaman adımı için girdi olarak kullanılmak üzere geri beslenir. Tüm girişlerin tam bir taramasının sonunda, bir sonraki dönem, önceki girişte olduğu gibi aynı girişlerin ve zaman adımlarının yeni bir taramasıyla başlatılır (Graupe, 2007: 233-234). Giriş sayısı çıkış sayısından farklı olabilmektedir. Böyle bir ağ mimarisi Şekil 2.25'de gösterilmiştir.



Şekil 2.25. Tekrarlayan sinir ağı yapısı (3 giriş / 2 çıkış) (Graupe, 2007)

Şekil 2.24 ve 2.25'deki her iki yapı, temel ağların (bir zaman aşamasından diğerine geri besleme hariç) tekrarlanan yapıda zaman aşamalarını hesaba katmak için m-kez tekrarlandığı bir yapıya eşdeğerdir. Şekil 2.25'de üç giriş ve iki çıkışlı bir mimari yapı söz konusudur.

2.2.4.7. Yapay sinir ağlarının uygulama alanları

Yapay zekânın alanlarından biri olan YSA, makinelerin öğrenmesine yönelik araştırmaları kapsamaktadır. Bilgisayar teknolojisi ve sistemleri artık hayatın

çok önemli bir parçasıdır. Artık her alanda makine öğrenmesinden faydalanılmaktadır. Bilgisayar sistemleri geçmişte sadece hesaplama işlerinde, veri transferlerinde kullanılırken zamanımızda büyük miktardaki verileri işleyen ve bu işlenen veriler hakkında çıkarımlar yapabilen, ilişkiler kurabilen sistemler haline gelmiştir. Matematiksel işlemlere dönüştürülemeyen olaylar birçok alanda makineler tarafından çözülebilmektedir. YSA, finansal problemlerden mühendislik ve tıp bilimine, üretim teknolojilerinden arıza tespit ve analizlerine kadar fazlaca alanda kullanılmaktadır (Ağyar, 2015a: 22). Bu alanlarda kullanılan YSA uygulamaları Tablo 2.6’da belirtilen sınıflardan birine uygundur:

Tablo 2.6. YSA ve Uygulama Alanları (Elmas, 2007)

Uygulama	Ağ Türü
Öngörü	Geri-Yayılm Ağ Delta Bar Delta Genişletilmiş Delta Bar Delta Yüksek Seviyeli Ağlar Özörgütlemeli Harita Ağ Perceptron
Sınıflandırma	Geri-Yayılm Ağ Öğrenme Vektörü Nicelemesi Perceptron Olasılıksal Sinir Ağları Kohonen Ağ Boltzmann Makinesi
Veri Birleştirilmesi	Hopfield Boltzmann Makinesi Hamming Ağ İki Yönlü Çağırışım Belleği Yığın Ağları Vektör Nicelemesi Ağ
Veri Kavramlaştırılması	Uyarlanır Rezonans Ağ Özörgütlemeli Harita Ağ
Veri Süzülmesi	Yeniden Dolaşım
Resim veya Görüntü İşleme	Geri-Yayılm Ağ Perceptron

Yapay zekânın alt dallarından biri olan YSA’nın uygulama alanları oldukça fazladır. Aşağıda uygulama alanlarından bazıları açıklanmıştır:

2.2.4.7.1 Finans, borsa ve kredi kartı alanında YSA kullanımı

Finans dünyasında YSA fazlaca kullanılmaktadır. İçinde Merrill Lynch ve Co., Salomon Brothers, Shearson Lehman Brother Inc, Citibank ve World Bank’ın

bulunduđu finansal kurumlar tahmin ve öngörüde bulunmak için YSA'ları kullanmaktadırlar. Manhattan Bank, YSA'lardan oluşan bir ödünç para risk inceleme sistemi kullanmaktadır. American Express, Mellon Bank, First USA Bank gibi bazı bankalar sahtekârlığı önlemek için YSA kullanmaktadırlar. Borsa şirketleri deđişimleri incelemek ve öngörüde bulunmak için YSA kullanmaktadırlar. Borsa hedef sistemi Churchill System tarafından geliştirilmiş ve Veratex Corp. Tarfından kullanılmaktadır. Bu şirket borsa stratejilerini ve ödemelerinin kesilmesini ve potansiyel müşteri listelerinden gelecekteki müşteri tahminlerini YSA ile yapmaktadır (Elmas, 2007: 161).

Ayrıca aşağıda sıralanan uygulamalarda YSA kullanılmaktadır (Udrescu ve Ilie, 2009: 1081):

- Piyasanın eğilimlerinde,
- Borsa dinamiklerinde,
- Müşterilerin talep veya piyasa eğilimleri tahminine dayalı karar vermede,
- Belirli ürünler için fiyat evriminde,
- Kredi ve kredi teklifi ile ilgili risklerde,
- Şirketin faaliyetleri üzerinde büyük etkisi olan diđer ekonomik faaliyetlerde YSA kullanılmaktadır.

2.2.4.7.2. Endüstriyel alanda YSA kullanımı

YSA'ların oldukça fazla sayıda endüstriyel kullanımları mevcuttur. Bunlardan bazıları aşağıda sıralanmıştır (Öztemel, 2016: 205):

- Endüstriyel proseste fırınların ürettiđi gaz miktarının tahmin edilmesinde kullanılmaktadır.
- İmalatta, ürünlerin tasarımı, proses ve makinelerin bakımı ve arıza-hata tespitinde kullanılmaktadır.
- Otomobillerde otomatik rehber sistemlerinin geliştirilmesinde kullanılmaktadır.
- Robotlarda görme sistemlerinin geliştirilmesinde kullanılmaktadır.
- Araba pistonlarının üretim şartlarının belirlenmesinde kullanılmaktadır.
- Elektronik yonga hata analizlerinde kullanılmaktadır.

- Optimizasyon çalışmalarında kullanılmaktadır.
- Müşteri tahmini ve pazar verilerinin değerlendirilmesinde kullanılmaktadır.
- Kömür güç istasyonlarının çevrimiçi karbon akımının ölçülmesinde kullanılmaktadır.
- İşlerin makinelere atanmasında kullanılmaktadır.
- Gezgin satıcı problemlerinde kullanılmaktadır.

2.2.4.7.3. Tıp, uzay, otomotiv ve haberleşme alanında YSA kullanımı

YSA, tıp, uzay, otomotiv ve haberleşme alanlarında da sıklıkla kullanılmaktadır. Bu alanlardaki uygulamalar aşağıda sıralanmıştır (Doğan, 2010: 38):

- EEG ve ECG gibi tıbbi sinyallerin analizi ve kanserli hücrelerin analizinde kullanılmaktadır.
- Protez tasarımı, transplantasyon zamanlarının optimizasyonu ve hastanelerde giderlerin optimizasyonunda kullanılmaktadır.
- YSA'larda bir dinamik öğrenme algoritması kullanılarak anten dizi elemanlarından elde edilen işaretler arasındaki faz farklılıklarının karşılaştırılmasıyla radar izleme gerçekleştirilmektedir.
- Savunma sanayi silahların otomasyonu ve hedef izleme, nesnelere/görüntüleri ayırma ve tanıma, yeni algılayıcı tasarımı ve gürültü önleme vs. gibi alanlara uygulanmaktadır
- Haberleşme, görüntü ve veri sıkıştırma, otomatik bilgi sunma servisleri, konuşmaların gerçek zamanda çevirisi vs. gibi alanlarda kullanılabilir.
- Uçaklarda otomatik pilot sistemi otomasyonu, ulaşım araçlarında otomatik yol bulma/gösterme, robot sistemlerin kontrolü, doğrusal olmayan sistem modelleme ve kontrolü, elektrikli sürücü sistemlerin kontrolü vs. gibi alanlarda kullanılabilir.

2.2.4.8. Yapay sinir ağlarının güçlü yönleri

Yapay sinir ağı modelleri daha az resmi istatistik eğitimi gerektirmektedir. Çalışan yapay sinir ağı modelleri, yeni gelen veri kümesinin sinir ağının yazılım

durumuna bağılı olarak kısa bir süre içinde geliştirilip güncellenebilmektedir. Geleneksel lojistik regresyon kullanılarak analiz edilebilen herhangi bir veri seti, nöral ağ tabanlı bir tahmin modelini geliştirmek için de kullanılabilir. Verilerin bazı dönüşümleri kullanılan yazılıma bağılı olmasına rağmen, sinir ağları hem sürekli hem de kategorik girdi ve çıktı değişkenleri kullanarak eğitilebilir. Veriler normalleştirildiğinde ağ en iyi şekilde çalışmaya eğilimlidir. Nöral ağ yazılım paketleri, ticari, basit, kullanıcı dostu paketlerden çoklu eğitim algoritmalarına sahip daha karmaşık paketlere kadar çeşitlilik gösterir. Bu çeşitli yazılımlar ile problemlerin çözümüne daha hızlı ve doğru ağ yapısı oluşturularak erişilebilmektedir. Nöral ağlar, bağımsız ve bağımlı değişkenler arasındaki karmaşık doğrusal olmayan ilişkileri belirleyebilmektedir. Sinir ağları, bağımsız ve bağımlı değişkenler arasındaki herhangi bir karmaşık doğrusal olmayan ilişkiyi örtük olarak algılama yeteneğine sahiptir. Bir sinir ağındaki tahmin değişkenleri genellikle her gizli düğümde ve çıkış düğümünde doğrusal olmayan bir dönüşüme uğramaktadır. Böylece bir nöral ağ potansiyel olarak doğrusal olmayan lojistik fonksiyonun olduğu bir lojistik regresyon modelinden çok daha karmaşık doğrusal olmayan ilişkileri modelleyebilmektedir. Ampirik gözlemler, veri kümelerinde karmaşık doğrusal olmayan ilişkiler olduğunda, sinir ağ modelleri geleneksel regresyon tekniklerinden daha iyi uyum sağladığını göstermektedir. Sinir ağları olası tüm tahmin değişkenleri arasındaki ilişkiyi tespit etme yeteneğine sahiptir. Ayrıca sinir ağları çoklu farklı eğitim algoritmaları kullanılarak geliştirilebilmektedir (Tu, 1996: 1228-1229).

Özetle, YSA, diğer istatistikî metotların ihtiyaç duyduğu varsayımlara ihtiyaç duymamaktadır. Uyarlanabilir ve esnek oluşu ağın daha sonrada gelişmesine olanak sağlamaktadır. Ağa sunulan ağırlıkların güncellenmesi mümkündür ve doğrusal olmayan yapılar modellenmektedir yani problemin doğrusal olması gerekmemektedir. YSA bilgiyi saklama özelliğine sahiptir. Bu sayılan özellikler YSA'ları üstün kılmaktadır.

2.2.4.9. Yapay sinir ağlarının zayıf yönleri

YSA'nın daha önce belirtilen üstünlüklerinin yanında zayıf yönleri de mevcuttur. Bunlar (Öztemel, 2016: 34-35):

- YSA bir makine öğrenmesi olduğundan donanım bağılı çalışmaktadır. YSA bilgiyi işleyebilmeleri için paralel çalışan işlemciler ile problemlere çözüm üretmektedirler. Günümüzdeki makinelerin birçoğunun seri çalışması ve tek bir bilgiyi işleyebilmesi sorun oluşturmaktadır. Ayrıca ağı nasıl oluşturulması gerektiğini açıklayacak sabit kuralların olamaması başka bir dezavantajı oluşturmaktadır.
- YSA'nın oluşturulmasında deneme yanılma yolu kullanılmaktadır. Bu yolun kullanılması önemli bir problemdir. Eğer çözümünü bulmak istediğimiz problem için uygun ağ oluşturulamaz ise problemin çözülmesi zorlaşır. Bir çıktı oluşsa bile bunun en iyi çözüm olduğunu garanti edilemez. YSA kabul edilebilir çözümler üretebilir fakat bu çözümlerin optimum çözüm olduğunu söyleyemez.
- YSA'da ağı parametre değerlerinin belirlenmesinde bir kural olmaması başka bir problemdir. Bu durum en iyi (optimum) çözümler bulmayı zorlaştıran etkenlerden biridir. Parametreler kullanıcının tecrübelerine bağlı olarak belirlenir. Her problemin parametre değerleri ayrıdır ve bu da bir dezavantajdır.
- YSA'da ağı öğreneceği problemin ağa tanıtılması önemli bir problemdir. YSA sadece sayısal bilgiler ile işlem görmektedir. Problemin sayısal gösterime dönüşümü şarttır. Bu ise kullanıcının tecrübesine bağlıdır. Uygun ve doğru bir dönüşüm mekanizmasının oluşturulamamış olması problemin çözüme ulaşmasını engelleyebilir.
- Ağı eğitiminin ne zaman sonlanacağına ilişkin karar vermek için uygulanacak bir yöntem yoktur. Ağı örnekler üzerindeki hatasının belli bir değerin altına inmesi eğitimin sonlandırılması için yeterli sayılmaktadır. Fakat optimum öğrenmenin gerçekleştiği söylenemez. Oluşan sadece iyi çözümler üretebilen bir ağ yapısıdır.

YSA'nın nedensel ilişkileri açık ve net bir şekilde tanımlamada sınırlı bir yeteneğe sahip bir "kara kutu" olduğu ifade edilmektedir. YSA'ları her alanda kullanmak bazen optimum çözümler üretmede sıkıntı yaratmaktadır. YSA'da çok fazla hesaplama işlemi yapıldığından, makine üzerinde yoğun bir işlem aritmetiği çalışmakta bu durumda zaman kaybı yaratabilmektedir (Tu, 1996: 1229-1230). Ağa

girilecek veri sayısı önemlidir. Ağın tam olarak genelleştirme yapabilmesi için yeterli miktarda veriyle ağ eğitilmelidir. Aksi durumda yanlış eğitime (overfitting-ezberleme) durumları ortaya çıkacaktır (Hamzaçebi, 2011: 81).

2.2.5. Destek vektör makineleri

Veri madenciliğini kullanarak problemlerin çözümü için geliştirilmiş önemli makine öğrenimi algoritmalarından biri destek vektör makineleridir. Makine öğrenimi ve veri madenciliği kullanılarak sınıflandırma problemlerinin çözümünde kullanılabilir. Daha çok bankacılık ve sigortacılık, tıp, biyoloji, kimya, sosyal medya, endüstriyel sektörler ve finans gibi alanlarda sınıflandırma problemlerinin çözümünde kullanılmaktadır. Son yıllarda, sınıflandırma problemlerinin çözümünde oldukça başarılı sonuçlar veren bir makine öğrenmesi algoritması olan Destek Vektör Makineleri (Support Vector Machines) sıkça kullanılmaktadır (Ayhan ve Erdoğan, 2014: 176).

Destek vektör makineleri (DVM) ilk defa Vapnik (1998) tarafından ikili sınıflandırma ve regresyon problemlerinin çözümünde kullanılan denetimli bir öğrenme yöntemidir. Çekirdek fikrini Aizerman vd. (1964) geniş marjlı sınıflara başarılı bir şekilde uygulaması ile güçlü araçlar olduklarını kanıtlamışlardır. Günümüzde DVM 'ler meme kanseri teşhisi, tahmin ve öngörü, finansal tahminler, öneri sistemleri, veri tabanı pazarlaması ya da protein homolojilerinin saptanması, metin kategorizasyonu ya da yüz tanıma vb. gibi çeşitli araştırma ve mühendislik alanlarında kullanılmaktadır. DVM süreci üç aşamalı adımda tanımlanır. İlk olarak, Vapnik ve Lerner (1963) optimal hiper düzlemi, yani en geniş marja sahip eğitim örneklerini ayıran lineer sınıfın inşa edilmesini önermiş, daha sonra Guyon vd. (1993) bir çekirdek fonksiyonu tarafından tetiklenen öznelik uzayında optimal hiper düzlem inşa etmeyi önermiştir. Son olarak, Cortes ve Vapnik (1995) bazı örneklerin kenar boşluğunu ihlal etmesine izin vererek sorunların en iyi şekilde ele alındığını göstermişlerdir. (Bordes, 2010: 33).

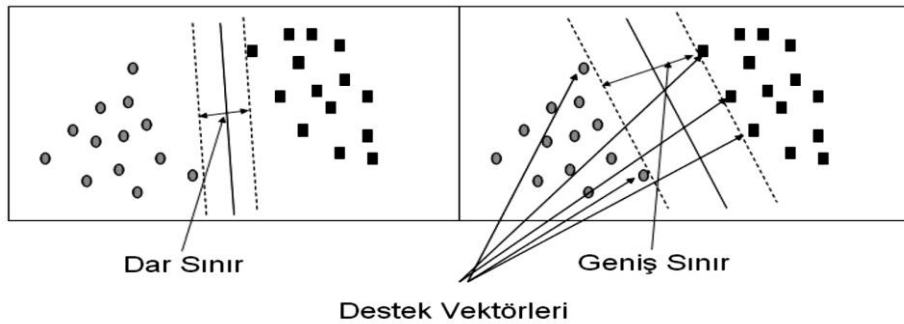
DVM'ler sınıflandırma ve regresyon problemlerinin çözümünde kullanılabilen, veri madenciliğinde kullanılan algoritmalarının içinde en uygun ve doğru metotlardan biridir. İstatistiksel öğrenme teorilerinin içinde sağlam bir teorik

temele sahiptir. DVM'nin kökeni Vapnik Chemonvekis Dimension(VC) içinde yer alan yapısal risk minimizasyon prensibine dayanmaktadır. DVM poligom makine öğrenmesi, radyal tabanlı fonksiyon ağ ve iki katmanlı algılayıcı fonksiyonlarını içermektedir (Kaytez, 2012: 68).

Yapısal risk minimizasyonu, makine öğrenmesinde kullanılan tümevarım yöntemlerindedir. Makine öğreniminde kullanılan yapı sonlu bir veriden kullanılmaktadır. Bu seçilen veriler çoğu zaman overfitting (aşırı öğrenme) durumuna sebebiyet vermektedir. Yapısal risk minimizasyonu bahsedilen overfitting problemini dengeler fakat bu aşamada eğitim başarısından ödün verilir. Ne kadar ödün verilse de yapısal risk minimizasyonu dolaylı olarak problemin çözümünü için daha iyi çıkarımlar yapılmasını sağlar (Erdal, 2011: 47).

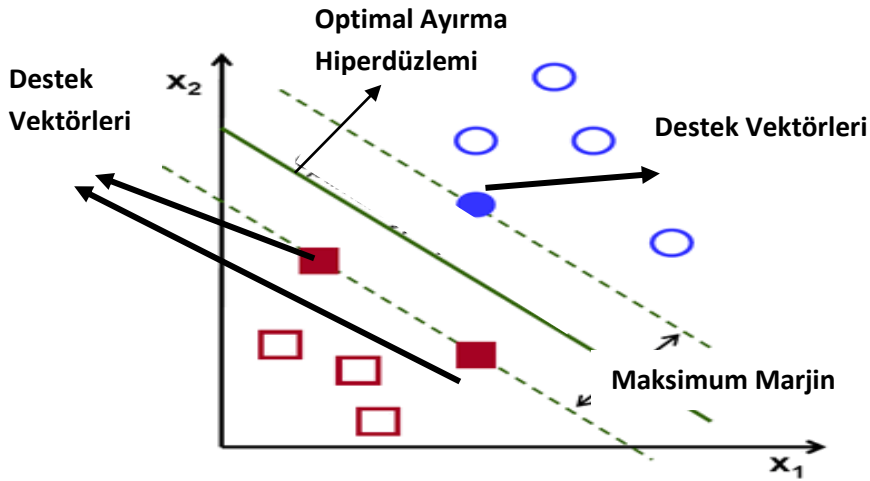
Problem çözümünde kullanılan eğitim setinde herhangi bir hata bulunmadığı takdirde DVM, Vapnik Chemonvekis Dimension (VC) boyutu değerini minimuma ulaştırmaya çalışır. Amaç beklenen risk olasılığını azaltarak iyi bir çıkarım yapma yeteneği elde etmektir. Eğitim setinde hatanın mevcut olduğu durumda DVM, tanıma doğruluğu ile öğrenme makinesinin karmaşıklığı arasında denge sağlayan doğru VC boyutu değerinin bulunmasını sağlar. Bu yapı sayesinde, boyut sıkıntısı DVM tarafından çözülür. Üste bahsedildiği üzere DVM regresyon problemlerinin yanında sınıflandırma problemlerinde de kullanılan bir algoritmadır. Sınıflandırma problemlerinin birkaç türü vardır. Bunların en başında eğitim hatasının olmadığı liner (doğrusal) ayrılabilirlik durumlarıdır. Bu durumlarda DVM giriş uzayında doğrusal bir ayırıcı fonksiyon kullanılır. Diğer durum ise, eğitim hatasının bulunmadığı doğrusal olmayan ayrılabilirlik durumudur. Bu tip durumlarda DVM giriş uzayında doğrusal bir sınıflandırma gerçekleştirmez. Bu sebeple, en başta çekirdek (kernel) fonksiyonları ile giriş uzayından nitelik uzayına dönüşüm yapılır. Daha sonraki aşamada DVM, nitelik uzayında doğrusal ayırıcı fonksiyonunu oluşturur. Eğitim hatasının olduğu durumlarda sisteme pozitif değerli bir esneklik parametresi eklenir ve aynı işlemler uygulanır. DVM, gerek sınıflandırma gerekse de regresyon analizlerindeki öğrenme problemlerinde, ikinci dereceden amaç fonksiyonuna sahip bir optimizasyon problemi formunda temsil edilir (Çomak, 2008: 37).

DVM'nin sınıflandırma problemlerinde iyi bir genelleme yapma konusunda başarılı olduğu yukarıda belirtilmişti. İki sınıfı, sınırlara en yakın iki örnek arasındaki mesafeyi maksimize edecek hiperdüzlemin sınırlarına en yakın örnek vektörlere, destek vektörleri denir. Tek boyutta boyut ayırıcı bir nokta iken, iki boyutta bir doğru, üç boyutta ise bir düzlem halini almaktadır. Doğru bir sınıflandırma elde edebilmek için, sınıflara ayırmak istenen iki sınıfın arasından geçen boyut ayırıcının (hiper düzlemin) sınırı maksimize edilmelidir. Şekil 2.26'da görülen doğrular hiper düzlemlerdir ve iki boyutlu uzayın hiper düzlemi (hyperplane) bir doğrudur. Doğru bir sınıflandırmada problemin içeriğine uygun bir hiper düzlemi elde edebilmek için iki kümenin veri setinin en yakın üyelerinin üzerinden iki paralel doğru geçirilir ve bu iki doğrunun tam ortasındaki doğru hiper düzlemi gösterir (hyperplane). Şekilde görülen paralel doğrular ise hiper düzlemin (hyperplane) sınırlarını oluşturmaktadır. Destek vektörleri ise Şekil 2.27'deki veri kümelerinin en yakın üyelerinin üzerinden geçen vektörlerdir (Erdal, 2011: 48).



Şekil 2.26. Hiper düzlem Sınıflandırması (Erdal, 2011)

Optimal ayırma hiper düzlemi, iki sınıfı ayırır ve her iki sınıftan en yakın noktaya olan mesafeyi maksimuma çıkarır (Vapnic, 1998). Bu, ayırt edici hiper düzlem problemine benzersiz bir çözüm sunmanın yanı sıra, eğitim verilerinin iki sınıfı arasındaki marjı en üst düzeye çıkararak, test verilerinde daha iyi sınıflandırma performansı sağlar (Hastie vd., 2009: 132).



Şekil 2.27. Destek Vektörleri ve Optimal Hiperdüzlem

2.2.5.1. Doğrusal olarak ayrılabilen DVM

DVM formülasyonları, konveks optimizasyon teorisi kapsamında yapılır. Genel metodoloji, problemi birincil ağırlık uzayında kısıtlı bir optimizasyon problemi olarak formüle etmeye başlamak, daha sonra Lagrangian'ı formüle etmek, daha sonra optimize koşullarını almak ve nihayet Lagrange çarpanlarının ikili uzayındaki problemi çözmektir. İkincisi destek değerleri olarak adlandırılacaktır (Suykens vd., 2005: 31).

Eğitim veri setinin doğrusal olarak ayrılabilme durumunda DVM, en büyük sınıra sahip ayırma hiper düzlemini bulmaya çalışır. Söz konusu ayırma hiper düzleminin bulunabilmesi için veri setindeki örneklerin aşağıdaki koşulları sağlaması gerekmektedir (Ayhan ve Erdoğan, 2014: 179):


$$f(x_i) = (w, x_i) + b \geq +1, y_i = +1 \quad [2.23]$$

$$f(x_i) = (w, x_i) + b \leq -1, y_i = -1 \quad [2.24]$$

Yukarıdaki eşitsizlik tek bir formüle indirilebilir;

$$y_i [(w x_i + b) \geq 1, i = 1, \dots, N \quad [2.24]$$

$$wx + b = 0 \quad [2.25]$$



Şekil 2.28. Doğrusal sınıflandırma: İki boyutlu bir giriş alanında görüntülenen benzersiz bir ayırıcı hiper düzlemin tanımı (Suykens vd., 2005)

Şekil 2.28'deki H_1 ve H_2 hiper düzlemleri görülmektedir. Bu düzlemlerin üzerinde destek vektörler mevcuttur (Şekil 2.27). Marj, kesikli çizgiler arasındaki mesafedir. X destek vektörü ile H_2 düzlemi arasındaki uzaklık;

$$d = \frac{|wx_i + b|}{\|w\|} = \frac{1}{\|w\|} \quad [2.26]$$

formülü ile hesaplanır. X_1 destek vektörü ile H_2 düzlemi arasındaki mesafe;

$$m = 2d = \frac{2}{w} \quad [2.27]$$

olur. Eşitliğe dayanan doğrusal programlama sorunlarının çözümünde kullanılan amaç fonksiyonu ve kısıt denkleminde oluşan ekstremum noktalarının bulunmasında kullanılan bir yöntem olan Lagrange çarpanları yöntemi ile bu optimizasyon problemi çözülür (Erdal, 2011: 50).

$$\text{Kısıt denklemleri; } f(x_i) = (w, x_i) + b \geq +1, y_i = +1 \quad [2.28]$$

$$f(x_i) = (w, x_i) + b \leq -1, y_i = -1 \quad [2.29]$$


Lagrange fonksiyonunu elde etmek için;

$$b_1 = f(x_1, x_2, x_3, \dots, x_n) \text{ amaç fonksiyonu} \quad [2.30]$$

$$g_1(x_1, x_2, x_3, \dots, x_n) = b_1 \quad [2.31]$$

$$g_2(x_1, x_2, x_3, \dots, x_n) = b_2 \quad [2.32]$$

$$g_3(x_1, x_2, x_3, \dots, x_n) = bn \quad [2.33]$$



Şekil 2.29. Lagrange Çarpanları (Law, 2018)

$a_1, a_2, a_3, \dots, a_n$ lagrange çarpanları olarak adlandırılır (Şekil 2.29) ve langrange fonksiyonu şu şekilde gösterilir:

$$L(x_1, x_2, x_3, \dots, x_n, a_1, a_2, a_3, \dots, a_n) = f(x_1, x_2, x_3, \dots, x_n) - \sum_{i=1}^n a_i [g_i(x_1, x_2, x_3, \dots, x_n) - b_i] \quad [2.34]$$

$f(x_1, x_2, x_3, \dots, x_n)$ fonksiyonunu maksimize ve minimize eden noktaların bulunması gerekmektedir. Bunun için aşağıdaki eşitsizliklerin çözülmesi gerekmektedir;

$$\frac{\partial L}{\partial x_i} = \frac{\partial f}{\partial x_i} - \sum_{i=1}^m a_i \frac{\partial g_i}{\partial x_i} = 0 \quad (i = 1, 2, 3, \dots, n) \quad [2.35]$$

$$\frac{\partial L}{\partial a_i} = -g_i(x_1, x_2, x_3, \dots, x_n) + b_i = 0 \quad (i = 1, 2, 3, \dots, m) \quad [2.36]$$

Yukarıdaki işlemler bize optimum noktaları gösterecektir.

$a_{i>0}$ = destek vektörler

$y_i [(w x_i + b) \geq 1]$ Eşitsizliği liner olmayan problemlerin en uygun çözümümde kullanılan langrange çarpanları yönteminin genelleştirilmiş şekli olan Karush- Khun-Tucker koşulları teoremi kullanılarak langrange çarpanlarının sıfırdan

farklı olduğu noktalarda aşağıdaki eşitliğe dönüşür. Eşitlik kısıtlı doğrusal olmayan modellere Lagrange çarpanları kullanılırken eşitsizlik kısıtlı problemlere de Kuhn-Tucker Koşulları uygulanmaktadır (akt:Erdal, 2011; Karush, 1939; Kuhn, 1951).

$$a_i[y_i(wx_i + b) - 1] = 0 \quad i = 1,2,3 \dots, n \quad [2.37]$$

Lagrange fonksiyonunu aşağıdaki şekilde yazılabilir:

$$L(w, b, a) = \frac{1}{2} \|w\|^2 - \sum_{i=1}^n a_i [y_i (wx + b) - 1] \quad [2.38]$$

$$\frac{\partial L(w_i, b, a)}{\partial w} = w - \sum_{i=1}^n y_i a_i x_i = 0 \quad \rightarrow \text{türev işlemi} \quad [2.39]$$

$$\frac{\partial L(w_i, b, a)}{\partial b} = \sum_{i=1}^n y_i a_i = 0 \quad \rightarrow \text{türev işlemi} \quad [2.40]$$

Buradan; $w = \sum_{i=1}^n y_i a_i x_i$ $0 = \sum_{i=1}^n y_i a_i$ [2.41] elde edilir. Bu denklemlere Karush-Kuhn-Tucker koşulları denilmektedir. $L(w, b, a)$ Fonksiyonunu aşağıdaki şekilde ifade edilir:

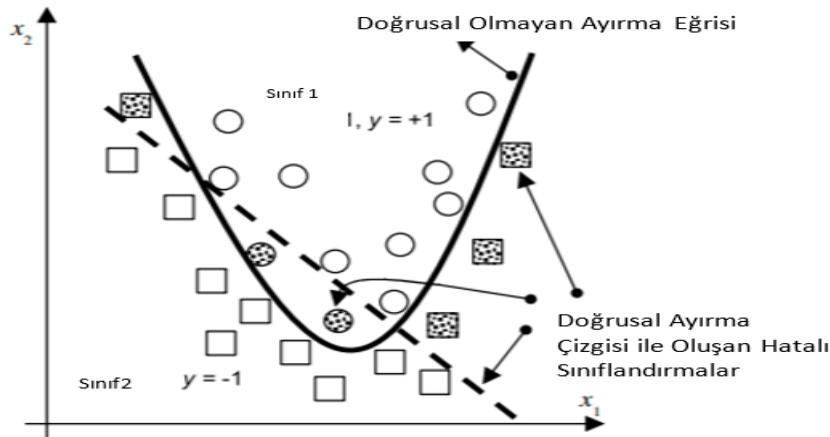
$$L(w, b, a) = \sum_{i=1}^n a_i - \frac{1}{2} \sum_{i=1}^n \sum_{j=1}^n a_i a_j y_i y_j (x_i x_j) \quad [2.42]$$

2.2.5.2. Doğrusal olarak ayrılamayan DVM

Gerçek hayatta verilerin doğrusal olarak ayrılabilirdiği durumlar çok mümkün değildir. Verilerin doğrusal olarak ayrılmadığı durumlar, doğrusal DVM'lerle çözülememektedir. Liner sınıflandırıcılar oldukça sınırlı kalmaktadır. DVM'ler böyle doğrusal olmayan problemlerle karşılaştığında, orijinal verilerden sınıflandırma özelliklerini çıkarmak için, doğrusal olmayan haritalama (mapping) yaparak, verileri n boyutlu orijinal girdi uzayından daha yüksek boyuta sahip belirleyici nitelik (feature) uzayına taşır $x \in R^n \rightarrow \Phi(x) \in R^f$ (Akşehirli vd., 2013: 23).

Doğrusal DVM sınıflandırıcılarından doğrusal olmayan DVM sınıflandırıcılarına genişletme oldukça basittir. $x, \phi(x)$ ile değiştirilebilir ve çekirdek hilesi uygulanabilir. Bununla birlikte, $\phi(x)$ 'nin sonsuz boyutlu ve dolayısıyla da w vektörünün olabileceği bilinmelidir. Doğrusal DVM'ler için, gerçekte destek değerleri (a) 'daki çifte problem olarak w 'deki primal problem eşit ölçüde iyi bir şekilde çözülebilir, bu, nonlinear DVM problemi için artık aynı değildir çünkü ilk problemde, bilinmeyen w , sonsuz boyutlu olabilir (Suykens vd., 2005: 37).

Yukarıda sunulan yaklaşımın güzel ve güçlü bir özelliği, doğrusal olmayan karar sınırları oluşturmak için kolaylıkla (ve nispeten basit bir şekilde) genişletilebilmesidir. Doğrusal olmayan bir karar hiper düzlemi yaratabilen DV makinesi, doğrusal olmayan ayrılabilir verileri sınıflandırabilecektir. Lineer bir sınıflandırıcıya göre vektör uzayında daha çabuk sınıflandırılacaktır. Doğrusal olmayan modellerin tasarlanması ihtiyacının çok basit bir örneği, Şekil 2.30'da gösterilmiştir. Doğru sınıflandırmayı yapan sınır çizgisi quadratikdir (ikinci dereceden). Artık hatasız lineer ayırıcı hiper düzlemin bulunamayacağı açıktır. Şekilde görüldüğü üzere en uygun lineer ayırıcı ile yapılan sınıflandırmada altı hatalı sınıflandırma yapılmıştır (dört yanlış sınıflandırılmış negatif veri ve iki yanlış sınıflandırılmış pozitif veri). Fakat doğrusal olmayan ayırma sınırını kullanırsak, iki sınıfı herhangi bir hata olmadan ayırmak mümkündür. Genel olarak, n-boyutlu girdi modelleri için, doğrusal olmayan bir eğri yerine, bir DV makinesi doğrusal olmayan bir ayırma hiper düzlem oluşturacaktır. Şekil 2.30'da doğrusal olmayan ayırma çizgisi (düz), lineer olan (kesikli) şeklinde gösterilmiştir (Huang vd., 2006: 36-37).



Şekil 2.30. Veri Çakışması Yaşanmayan Doğrusal Olmayan Bir DVM (Huang vd.,2006)

Doğrusal DVM durumunu benzer şekilde, doğrusal olmayan DVM içinde yazılabilir (Suykens vd., 2005: 40-42);

$$w^T \Phi(x_k) + b \geq +1 \text{ eğer } y_k = +1 \quad [2.43]$$

$$w^T \Phi(x_k) + b \leq -1 \text{ eğer } y_k = -1 \quad [2.44]$$

Eşdeğer denklem;

$$y_k[w^T \Phi(x_k) + b] \geq 1, k = 1, 2, 3, \dots, N \quad [2.45]$$

Ayrılabilir veriler durumunda. Bu noktada $\Phi(\cdot): \mathbb{R}^n \rightarrow \mathbb{R}^{n_h}$ şeklindedir. n_h sayısı, nonlinear sınıflandırıcının birincil ağırlık uzayı temsilindeki gizli birimlerin sayısıdır. n_h , n_H boyutuna karşılık gelir.

$$y_x = \text{sign}[w^T \Phi(x) + b] \quad [2.46]$$

Daha sonraki aşamada optimizasyon problemi meydana gelir;

$$\min_{w,b,\varepsilon} j_p(w, \varepsilon) = \frac{1}{2} w^T w + c \sum_{k=1}^n \varepsilon_k \quad [2.47] \text{ öyle ki}$$

$$y_k[w^T \Phi(x_k) + b] \geq 1 - \varepsilon_k, k = 1, 2, \dots, N \quad [2.48]$$

$$\varepsilon_k \geq 0, k = 1, 2, \dots, N. \quad [2.49]$$

Bir Lagrangian yapısı kurulur:

$$L(w, b, \varepsilon; a, v) = j_p(w, \varepsilon) - \sum_{k=1}^n a_k (y_k[w^T \Phi(x_k) + b] - 1 + \varepsilon_k) - \sum_{k=1}^N v_k \varepsilon_k \quad [2.50]$$

$$\text{Lagrange çarpanları ile } a_k \geq 0, v_k \geq 0, k = 1, 2, \dots, N. \quad [2.51]$$

→Çözüm bize semer noktasını verir: $\max_{a,v}, \min_{w,b,\varepsilon} L(w, b, \varepsilon; a, v)$

$$\frac{\partial L}{\partial w} = 0 \rightarrow w = \sum_{k=1}^N a_k y_k \Phi(x_k) \quad [2.52]$$

$$\frac{\partial L}{\partial b} = 0 \rightarrow \sum_{k=1}^N a_k y_k = 0 \quad [2.53]$$

$$\frac{\partial L}{\partial \varepsilon_k} = 0 \rightarrow 0 \leq a_k \leq c, k = 1, 2, \dots, N. \quad [2.54]$$

İkinci dereceden programlama problemi yani dual problem oluşur;

$$\max_{a} j_D(a) = -\frac{1}{2} \sum_{k,l=1}^N y_k y_l K(x_k x_l) + \sum_{k=1}^N a_k \quad [2.55] \text{ öyle ki ;}$$

$$\sum_{k=1}^N a_k y_k = 0 \quad [2.56]$$

$$0 \leq a_k \leq c, k = 1, 2, \dots, N. \quad [2.57]$$

Bu kuadratik formda bir tane çekirdek hilesinden yararlanır.


$$K(x_k x_l) = \Phi(x_k)^T \Phi(x_l), k = 1, 2, \dots, N. [2.58]$$

Son olarak, doğrusal olmayan DVM sınıflandırıcı aşağıdaki formu alır:

$$f(x) = y(x) = \text{sign}[\sum_{k=1}^N a_k y_k K(x, x_k) + b] [2.59]$$

Yukarıdaki analizden yola çıkılarak DVM'ye, eğitim örnek kütleleri ve kerneller ile karar verildiği söylenebilir. Kernel çekirdek fonksiyonunun oluşturulması ve seçimi DVM'de problemin çözümü için oldukça önemlidir. Fakat kullanılacak kernel fonksiyonu pratikte doğrudan verilmektedir (Torun, 2008: 108).

5 ve 4 noktali yıldızlar, sırasıyla sınıf 1 ve sınıf 2 için destek vektörlerini gösterir.



Şekil 2.31. Doğrusal olmayan DVM sınıflandırması (Kecman, 2001)


Şekil 2.31'de giriş alanındaki karar sınırı, doğrusal olmayan bir ayırma çizgisidir. Gerçek ayırma çizgisi bir sinüs fonksiyonudur ve gösterilen her bir eğitim veri noktasında (daireler) yer alan Gaussian (RBF) kernelleri kullanılarak elde edilmiştir. Sınıf 1 için çoğu Destek Vektörleri $f(x)$ 'in arkasına gizlenmiştir (Kecman, 2001: 167).

2.2.5.3. Kernel (çekirdek) fonksiyonları

Çekirdek fonksiyonu fikri, potansiyel olarak yüksek boyutlu özellik alanı yerine giriş alanında gerçekleştirilecek işlemlerin yapılabilmesidir. Bu nedenle, iç

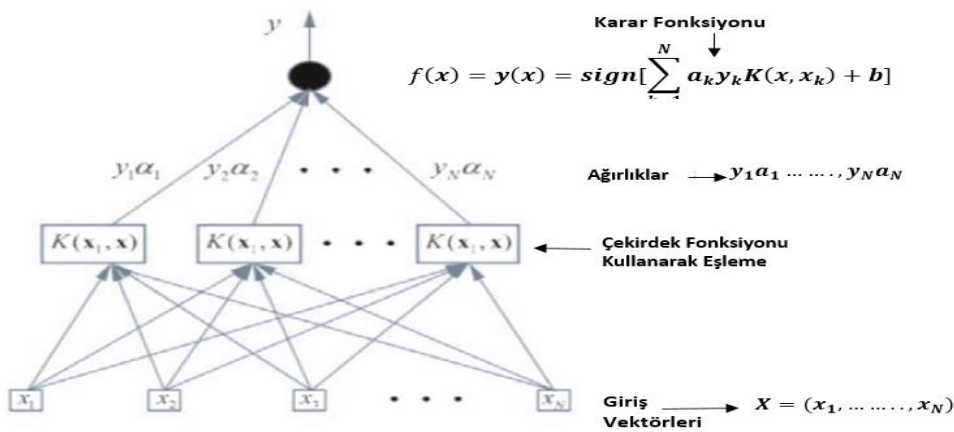
çarpım özellik alanının değerlendirilmesine gerek yoktur. Bu durum, boyutsallık sorununu (Curse of Dimensionality) ele almanın bir yolunu sağlar. Bununla birlikte, hesaplama hala kritik olarak sayıya bağlıdır. Yani yüksek boyutlu bir problemde iyi bir veri dağılımının sağlanması için genellikle geniş bir eğitim setine ihtiyaç duyulacaktır (Gunn, 1998: 19).

Kernel fonksiyon teorisinin temelleri Doğuran Çekirdekli Hilbert Uzayları (Reproducing Kernel Hilbert Spaces) teorisine dayanmaktadır. Doğuran Çekirdek, 20. yüzyılın başlarında, ilk olarak, harmonik ve biharmonik fonksiyonlar için sınır değer problemleri konusundaki çalışmalarında S. Zaremba tarafından kullanılmıştır. 1907'de, belirli bir durumda bir fonksiyon sınıfına karşılık gelen çekirdeği tanıtan ve çoğaltma özelliğini ifade eden ilk kişidir. Ancak herhangi bir teori geliştirmede ve tanıttığı çekirdeklere herhangi bir isim vermemiştir. 1909 yılında, J. Mercer, Hilbert tarafından geliştirilen integral denklemler teorisinde yeniden çoğaltma özelliğini tatmin eden fonksiyonları incelemiş ve bu işlevleri 'pozitif kesin kerneller' (positive definite kernels) olarak adlandırmıştır. Bu pozitif kesin kernellerin, iyi özelliklere sahip olduğunu göstermiştir. Ancak, uzun bir süre bu sonuçlar araştırılmamıştır. Daha sonra, çekirdeklerin çoğaltılması fikri üç Berlinli matematikçi G. Szegö (1921), S. Bergman (1922) ve S. Bochner (1922) tezlerinde ortaya çıktı. Özellikle, S. Bergman, harmonik ve analitik fonksiyonlar sınıfı için bir ve birkaç değişikende çekirdeklerin çoğaltılmasını sağladı ve onlara “çekirdek fonksiyonları” adını verdi (Okutmuş, 2005: 1). Daha öncede bahsedildiği gibi DV makineleri fikri: eğitim verilerini Φ ile yüksek boyutlu bir öznelik uzayına (feature space) eşler ve burada maksimum kenar boşluğuna sahip bir ayrık hiperdüzlem inşa eder (Şekil 2.32). Bu, giriş alanında doğrusal olmayan bir karar sınırı verir. Bir çekirdek fonksiyonu (kernel function) kullanılarak, ayırma hesaplamak mümkündür (Scholkopf ve Smola, 2001: 13).



Şekil 2.32. Yüksek Dereceli Çekirdek Fonksiyonu ile Öznitelik Uzayına Dönüşüm (Scholkopf ve Smola, 2001)

Karar fonksiyonunu kullanan bir öğrenme makinesine DVM denir. Ayrıca bir DVM oluşturmanın karmaşıklığının sadece destek vektörlerinin sayısına bağlı olduğunu ve özellik uzayının boyutlarıyla ilgisi olmadığını belirtmek gerekir. Şekil 2.33'de, SVM'nin şematik diyagramını göstermektedir. Diyagramda görüldüğü üzere DVM, optimum ayırma hiper düzlemini oluşturmak için giriş uzayını bir çekirdek fonksiyonu kullanarak yüksek boyutlu bir özellik alanına eşler (N. Zheng ve Xue, 2009: 168).



Şekil 2.33. Bir Çekirdek Fonksiyonu Kullanarak Yüksek Boyutlu Bir Özellik Alanına Eşleme (Zheng ve Xue, 2009)

Çekirdek fonksiyonlarının kullanılması ek bir hesaplama maliyeti getiriyor gibi görünse de, DVM ayırıcı fonksiyonu doğrusal olarak öznitelik uzayı üzerinde aramaya başladığından bu arama esnasında ek hesaplama maliyeti giderilir. Çekirdek

(kernel) fonksiyonlarını kullanmamızın basit nokta çarpımlarını kullanmaya göre önemli bir avantajı, tam olarak neyi haritaladığımızı bilmemizdir. Doğrusal olmayan DVM sınıflandırma ve regresyon analizlerinde genellikle iki esas problem ortaya çıkabilir. Bunlardan birincisi, haritalama fonksiyonunun seçimi durumudur. İkincisi ise boyut sıkıntısı problemidir. Eğer giriş uzayının boyutu büyük ise, o zaman nokta çarpımı işleminde çarpım matrisinin sayısal değerlerinin oluşturulması da çok fazla zaman almaktadır. DVM uygulamalarında Çekirdek fonksiyonu kullanmanın en büyük faydası, tüm değerlerin tekrar tekrar çarpım değerlerinin hesaplanarak bulunması yerine doğrudan çekirdek fonksiyonunda değerin yerine koyularak öznelik uzayındaki değerinin bulunmasıdır. Bu sayede, son derece yüksek boyutlu bir nitelik uzayı ile uğraşma olasılığı kalmaz. Aşağıda verilen Tablo 2.7’de uygulamalarda en çok kullanılan çekirdek (kernel) isimleri karşısında fonksiyonları ile belirtilmiştir (Çomak, 2008: 31).

Tablo 2.7. En Sık Kullanılan Çekirdek Fonksiyonları (Çomak, 2008)

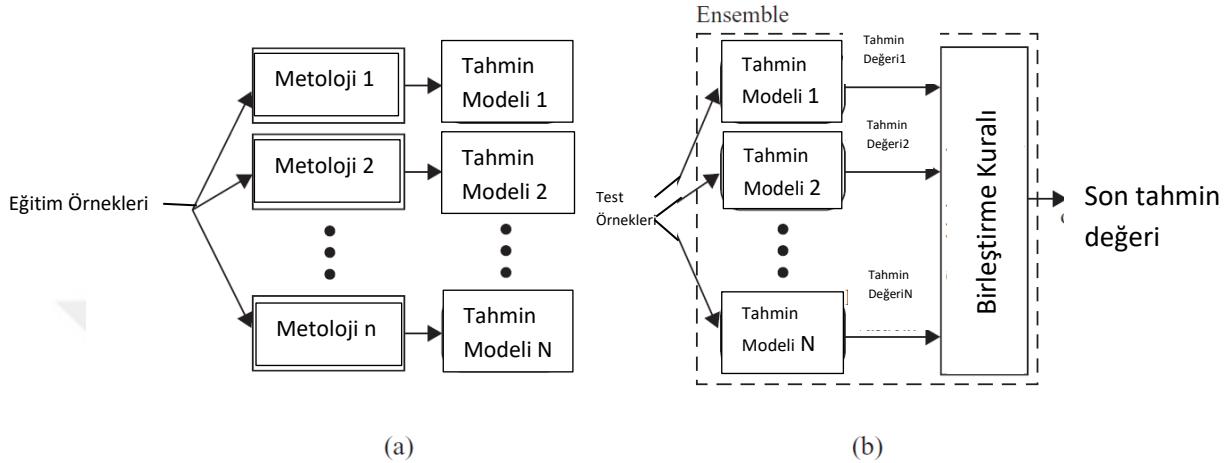
Çekirdek İsimleri	Çekirdek Fonksiyonları
Doğrusal	$K(x, y) = x \cdot y$
d. dereceden yüksek dereceli fonksiyon	$[K(x, y) = (x \cdot y) + 1]^d$
Çok katmanlı algılayıcı	$K(x, y) = \tanh(kxy - \theta)$
Gauss Yarıçap Temelli Fonksiyon	$K(x, y) = K(x - y) = \exp(-\frac{\ x-y\ ^2}{2\sigma^2})$
Üssel Yarıçap Temelli Fonksiyon	$K(x, y) = K(x - y) = \exp(-\frac{\ x - y\ }{2\sigma^2})$
Ters İkinci Dereceden	$K(x, y) = K(x - y) = (\ x - y\ ^2 + c^2)^{1/2}$
İnce Tabaka Spline	$K(x - y) = \ x - y\ ^{2n+1}$ $K(x, y) = K(x - y) = \ x - y\ ^{2n} \ln(\ x - y\)$
Oransal İkinci Dereceden	$K(x, y) = 1 - \frac{\ x - y\ ^2}{\ x - y\ ^2 + \theta}$
Dalga Yapılı	$K(x, y) = \frac{\theta}{\ x - y\ } \sin(-\frac{\ x - y\ }{\theta})$
B-spline	$K(x, y) = B_{2n+1}(x - y)$
Fourier Serisi (trigonometrik çok dereceli)	$K(x, y) = \frac{\sin(d + \frac{1}{2})(x - y)}{\sin \frac{(x - y)}{2}}$
Küresel	$1 - \frac{3\ x-y\ }{\theta} + \frac{1}{2}(\frac{\ x-y\ }{\theta})^3$ eğer $\ x - y\ < \theta$

2.2.6. Ensemble (Topluluk) öğrenme modeli

Eğer binlerce rastgele kişiye karmaşık bir soru sorup cevapları bir yerde toplandığını varsayarsak, çoğu durumda bu toplu cevabın bir uzmanın cevabından daha iyi olduğu görülecektir. Buna kalabalığın aklı denir. Benzer şekilde, Şekil 2.34'de görüldüğü üzere bir grup yordayıcının tahminleri toplanırsa (örneğin sınıflandırıcılar veya regresörler), genellikle tek tahminciye daha iyi tahminler alınması mümkündür. Bir grup tahminciye topluluk denir; bu nedenle, bu tekniğe topluluk (ensemble) öğrenmesi denir ve topluluk öğrenme algoritmasına (ensemble) topluluk yöntemi denir (Géron, 2017: 245).

Yapılan analizin tahmin gücünü ve doğruluğunu artırmak için geliştirilen ensemble öğrenme modelindeki temel fikir, eğitim örnekleri kullanılarak oluşturulan çeşitli öngörü modellerinden elde edilen sonuçları birleştirmektir. Modeldeki esas kilit nokta hata oranının minimuma indirilmesidir. Buradaki varsayım, grubun yeni bir örneği tek bir tahmin modeline kıyasla yanlış sınıflandırması olasılığının çok daha düşük olacağı varsayımıdır. Her biri rasgele tahminden en az daha doğru olan çoklu, bağımsız ve çeşitli “karar vericiler” birleştirilirken, doğru kararlar güçlendirilmelidir. Daha önce de bahsedildiği üzere ensemble öğrenme, topluluk fikrinin bireysel fikirden daha iyi sonuç çıkaracağı üzerine inşa edilmiştir. Örneğin bir kavanozda bulunan jelibonların sayısı üzerine tahmin geliştirilmesi eyleminde, grup ortalaması bireysel cevaptan daha iyi performans gösterecektir. Bir başka örnek üzerinden açıklanırsa, “Kim Milyoner Olmak İster?” adlı yarışma programında, yarışmacının emin olmadığı bir sorunun seyircilere (topluluk) sorulması yarışmacının performansını artırıcı bir olaydır. Ensemble öğrenme metodolojisi iki ardışık aşamadan oluşur: (a) eğitim aşaması ve (b) test aşaması. Eğitim aşamasında, topluluk yöntemi, Şekil 2.34'de gösterildiği gibi eğitim örneklerinden birkaç farklı öngörücü model üretmektedir. Bir test örneklerinin bilinmeyen bir değerini tahmin etmek için, topluluk metodu her bir tahmin modelinin çıktılarını toplar (Şekil 2.34 b). Bir ensemble yaklaşım tarafından oluşturulan entegre bir tahmin modeli, birkaç tahmin modelinden (Tahmin modeli 1, Tahmin modeli 2,.. Tahmin modeli N) ve Şekil 2.34 (b)'de gösterildiği gibi bir birleştirme kuralından oluşur. Topluluk öğrenme alanı hala göreceli olarak yenidir ve birden fazla sınıflandırıcı, sınıflandırıcı

füzyonu, uzmanların karışımı ya da fikir birliği toplamının birleşimi de dahil olmak üzere hangi öngörücü görevin yapıldığına bağlı olarak birkaç isim kullanılır (Kantardzic, 2011: 236).



Şekil 2.34. Ensemble model oluşturmak için eğitim aşaması ve test aşaması. (a) Eğitim aşaması; (b) Test aşaması. (Kantardzic,2011)

Bir ensemble model oluşturma iki adımdan oluşur: (1) çeşitli modeller oluşturmak ve (2) tahminlerini birleştirmek. Modeller; ağırlıklar, veri değerleri, kılavuzluk parametreleri, değişken altkümeler veya giriş uzayı bölümleri ile üretebilir. Kombinasyon ise oylama yoluyla gerçekleştirilebilir, ancak esas olarak özel durumlar olarak kapı ve danışman algılayıcılarla birlikte model tahmini ağırlıkları yapılır. Örneğin, Bayesian modelinin ortalamaları, gerideki eylemler ağırlıklandırılmış olası modellerin tahminlerini toplamaktadır. Bagging, eğitim veri setini (genellikle çeşitli karar ağaçları oluşturmak için) ön plana çıkarır ve çoğunluk oylamasını veya tahminlerinin ortalamasını alır. Radom Forest, birleştirilen ağaçlar arasında daha fazla çeşitlilik yaratmak için stokastik bir bileşen ekler. AdaBoost ve ARcing, değişken vaka ağırlıklarını değiştirerek modelleri tekrar eder ve modeller dizisinin tahminlerinin ağırlıklı toplamını kullanır (Seni ve Elder, 2010: 4-5).

Ensemble öğrenmede, Bagging ve Boosting metotları temel sınıflandırıcıların doğruluğunu artırmak için kullanılan yöntemlerdir. Her iki metotta da yeniden örnekleme yaparak kullanılan eğitim setinden türetilmiş çok sayıda örnek kümesi oluşturulur ve sonuçlar birleştirilerek tek bir sınıflandırıcı modeli elde edilir.

Bagging ve Boosting eğitim süreçlerinin işleyişi Tablo 2.8'de gösterilmiştir (Yıldırım, 2017: 29-30):

Tablo 2.8. Bagging ve Boosting Adımları (Yıldırım, 2017)

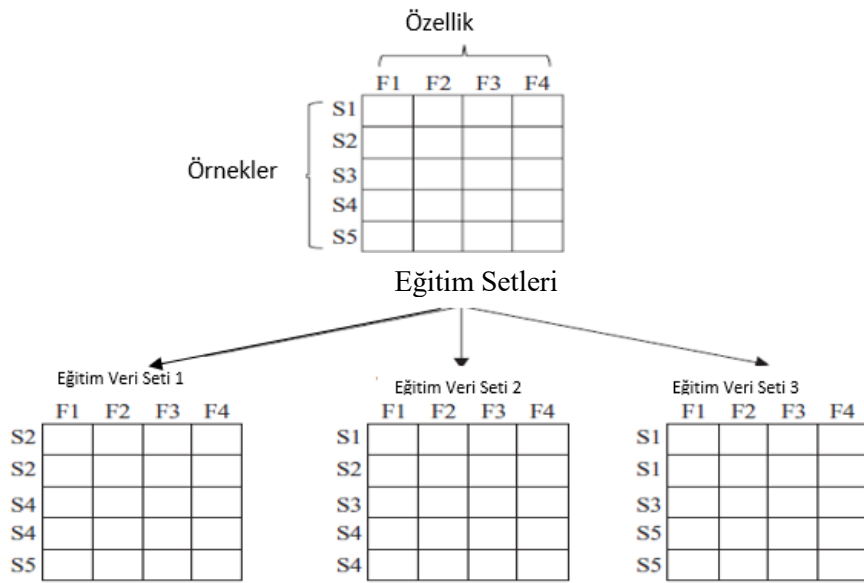
Bagging	Boosting
Adım 1. Orijinal eğitim setinden N adet rastgele seçilerek yeniden örneklenmiş eğitim setleri oluşturulur.	Adım 1. Orijinal eğitim setinden rastgele yeniden örneklendirilmiş bir alt eğitim seti oluşturulur.
Adım 2. Oluşturulan her bir eğitim seti seçilen öğrenim algoritmasına sokulur.	Adım 2. Oluşturulan eğitim seti öğrenim algoritmasından geçirilir.
Adım 3. Tüm sınıflandırıcılardan elde edilen sonuçların ortalaması alınarak tek bir model elde edilir.	Adım 3. Tahminlerde hatalı olan örneklerin ağırlıkları daha yüksek verilerek ikinci bir yeniden örneklendirilmiş eğitim seti oluşturulur.
	Adım 4. 3. Adım M adet gerçekleştirilerek tüm modellerden elde edilen sonuçların ağırlıklı kombinasyonu alınarak tek bir model elde edilir.

2.2.6.1. Bagging algoritması (Bootstrapping Aggregation)

Bagging (bootstrap aggregating), bir ensemble sınıflandırıcı oluşturmak için basit ama etkili bir yöntemdir. Bu yöntemle oluşturulan ensemble sınıflandırıcısı, çeşitli öğrenilmiş tek sınıflandırıcıların çıktılarını birleştirir. Bu, doğruluğu her bireysel sınıflandırıcının doğruluğundan daha yüksek olan bir sınıflandırıcı ile sonuçlanır. Spesifik olarak, topluluktaki her bir sınıflandırıcı, eğitim setinden (tekrarlamaya izin veren) alınan örneklerin bir örneği üzerinde eğitilmiştir. Tüm sınıflandırıcılar aynı indükleyici kullanılarak eğitilmiştir. Her örnekte yeterli sayıda eğitim örneği olduğundan emin olmak için her örneğin boyutunu orijinal eğitim setinin boyutuna ayarlamak yaygındır. Bagging işleminin temel avantajlarından biri, çeşitli gruplayıcı sınıflandırıcıları farklı işlemciler üzerinde eğiterek paralel moda kolayca uygulanabilmesidir (Rokach, 2010: 22-23).

Bagging metodolojisinde, tahmin modeli için belirlenmiş bir eğitim verisi, örnekleme dağılımına göre bir ilk örnek grubundan değiştirilerek alınan örneklerden oluşur. Örnekleme dağılımı, bir örneğin seçilme olasılığını belirler. Örneğin, örnekleme dağılımı tekdüze dağılım olarak önceden tanımlandığında, tüm N eğitim

örnekleri seçilen $1/N$ olasılıkla aynıdır. Aynı eğitim verilerinde, örnekleme değiştirme nedeniyle, bazı eğitim örnekleri birkaç defa görünebilirken, bazı durumlarda bir defa bile görünmeyebilir. Şekil 2.35'de, beş tane eğitim örneği (S1, S2, S3, S4, S5) ile dört özellik (F1, F2, F3, F4) olan örnek görünmektedir. Üç eğitim veri setinin tek tip dağılıma göre eğitim örneklerinden değiştirilerek rastgele seçilen örnekler tarafından oluşturulduğunu varsayalım. Her eğitim örneğinin eğitim veri setinin bir elemanı olarak seçilme olasılığı $1/5$ tir. Eğitim seti 1 de, S2 ve S4 iki kez görünürken, S1 ve S3 görünmez. Bagging, yalnızca eğitim verilerindeki küçük değişikliklerin belirgin şekilde farklı sınıflandırıcılara ve doğrulukta büyük değişikliklere yol açtığı dengesiz olmayan modeller kullanıldığında etkilidir (Kantardzic, 2011: 242).



Şekil 2.35. Bagging metodolojisi (Kantardzic, 2011)

Şekil 2.36'da, bagging algoritmasını kullanarak bir grup sınıflandırıcı oluşturmaya yönelik sözde kod gösterilmektedir (Breiman, 1996). Algoritma, bütün üyelerin eğitimi için kullanılan bir başlatma algoritması alır. Satır 6'daki durma kriteri, takım büyüklüğü T'ye ulaştığında eğitimi sonlandırır.

Gerekli olanlar= I (temel başlatıcı), T (iterasyon sayısı), S (orijinal eğitim seti), μ (örneklem sayısı)

1: $t \leftarrow 1$

2: tekrar

3: $S_t \leftarrow S$ 'den bir μ örneği alarak değiştirme

4: Eğitim seti olarak S_t ile birlikte I kullanarak M_t sınıflandırıcısını kurma

5: $t \leftarrow t+1$

6: $t > T$ oluncaya kadar.

Şekil 2.36. Bagging algoritması sözde kodu (Rokach, 2010: 23)

2.2.6.2 AdaBoost (Boosting)

İlk defa Y. Freund ve Schapire (1997) tarafından kullanılmıştır. Boosting, bagging'e benzer bir tekniktir. Boosting ve bagging her zaman aynı sınıflandırıcıyı kullanır. Ancak boostingte, farklı sınıflandırıcılar sırayla eğitilir. Her yeni sınıflandırıcı, önceden eğitilmiş olanların performansına dayalı olarak eğitilmiştir. Boosting, yeni sınıflandırıcıların daha önceki sınıflayıcılar tarafından yanlış sınıflandırılmış verilere odaklanmasını sağlar. Boosting, bagging'den farklıdır çünkü çıktısı tüm sınıflandırıcıların ağırlıklı toplamından hesaplanır. Ağırlıklar, baggingdeki gibi eşit değildir, ağırlıklandırma ancak sınıflandırıcının önceki yinelemede ne kadar başarılı olduğuna dayanır. Boosting algoritmasının birçok sürümü vardır, bunlardan en popüler olanı AdaBoost'dur (Harrington, 2012: 131).

Adaptive Boost'un kısaltması olan AdaBoost, başlangıçta 2 sınıf sınıflandırma problemleri için önerildi ve adını da "zayıf" (orta derecede doğru) temel sınıflandırıcıların performansını "artırma" yeteneğinden almıştır (Seni ve Elder, 2010: 56). Boosting algoritması bir örnek ile açıklanırsa, bir hastanın belirli semptomlarının olduğunu varsayalım. Hasta bir doktora danışmak yerine, birkaç doktora danışmayı seçer. Yaptıkları önceki teşhislerin doğruluğuna bağlı olarak her doktorun teşhis değerine bir ağırlık verdiğimizizi varsayalım. Kesin tanının tanımlanması işlemi ise ağırlıklı tanıların bir birleşimidir. Aslında boosting'in esası budur. Boosting algoritmasında, ağırlıklar her eğitim grubuna atanır (Han vd., 2011: 367-368).

Adaboost algoritması, zayıf sınıflayıcılardan oluşan bir komite oluşturulmasına dayanır. Zayıf sınıflayıcıların karar sınırları her bir öznitelik için pozitif ve negatif örneklerin ağırlıklı ortalaması ile hesaplanır. Sonraki aşamada hata oranı en düşük zayıf sınıflayıcılar kullanılarak güçlü bir sınıflayıcı oluşturur. Bu yapılan eylemlerden sonra güçlü sınıflayıcılar içerisinde yer almayan zayıf sınıflayıcılara ilişkin öznitelikler elenmiş olur AdaBoost yönteminin sözde kodu aşağıda gösterilmiştir (Tetik ve Bolat, 2011: 86-89):

Eğitim veri seti $(x_1, y_1), \dots, (x_n, y_n)$ olarak verilir. Burada y_i , negatif örnekler için 0, pozitif örnekler için 1 olarak kabul edilir.

- m pozitif örnek sayısını gösterirken n ise negatif örnek sayısını gösterir.

Ağırlıklar ise $w_{1,i} = \frac{1}{2m}, \frac{1}{2l}$ olacak şekilde her $y_i \in \{0,1\}$ için ilklendirilir.

- T = iterasyon sayısı, her $t=1, \dots, T$ için:

1. Ağırlıklar normalize edilir.

$$w_{1,i} \leftarrow \frac{w_{1,i}}{\sum_{j=1}^n w_{t,j}} \quad [2.60]$$

2. Her bir j özniteliği için, sadece bu j özniteliğini kullanan bir h_j sınıflayıcı eğitilir. Hata w_t ağırlığına göre ölçülür.

$$e_j = \sum_i w_i |h_j(x_i) - y_i| \quad [2.61]$$

3. En az e_t hatasına sahip h_t sınıflayıcı seçilir.

4. Ağırlıklar güncellenir:

$$w_{t+1,i} = w_{t,i} \beta_t^{1-e_i} \quad [2.62]$$

Burada x_i doğru olarak sınıflandırıldıysa $e_i = 0$, aksi durumda $e_i = 1$ olur.

$$\beta_t = \frac{e_t}{1-e_t} \text{ olarak hesaplanır.}$$

- Sınıflandırıcının son durumu şu şekilde olur:

Burada $\alpha_t = \log \frac{1}{1-\beta_t}$ alınır;

$$h_x = \begin{cases} 1, & \sum_{t=1}^T \alpha_t h_t(x) > \frac{1}{2} \sum_{t=1}^T \alpha_t \\ 0, & \text{diğer durumlarda} \end{cases} \quad [2.63]$$

AdaBoost yönteminde esas amaç, en güçlü zayıf sınıflandırıcıların bir araya getirilmesiyle güçlü bir sınıflandırıcının oluşturulmasıdır. Bundan dolayı AdaBoost metodunda her bir eğitim örneği için eşit bir D dağılımıyla başlar. Her iterasyonda

sınıflama performansına baęlı olarak en iyi zayıf sınıflandırıcı tespit edilir ve aęırlıklar güncellenir. Güncel deęerler ile bir olasılık daęılım fonksiyonu oluşturulur. İlerleyen adımlarda da bu işlemler tekrarlanır. Belirlenmiş sayıdaki işlem sonucunda en güçlü zayıf sınıflandırıcıların birleştirilmesiyle yüksek performanslı bir sınıflandırıcı elde edilmiş olur (Bulut, 2016: 155).



ÜÇÜNCÜ BÖLÜM

LİTERATÜR ARAŞTIRMASI

3.1. FİNANSAL BAŞARISIZLIK İLE İLGİLİ YURT DIŞI LİTERATÜR

Literatürde finansal başarısızlık tahmini ile ilgili yapılan birçok çalışmanın olduğu görülmektedir. Yapılan ilk çalışmalarda geleneksel istatistiki modeller, sonraki yıllarda ise yapay zekâ, veri madenciliği ve makine öğrenmesi teknikleri kullanılmıştır.

Merwin (1942) istatistiki herhangi bir analiz tekniği kullanmadığı çalışmasında beş sektörü esas almış ve 1000 işletmenin finansal oranlarını kullanmıştır. Analiz neticesinde bazı finansal oranların, finansal başarısızlığın önceden tespiti konusunda daha etkili olduğu sonucuna varmıştır. Daha sonraki yıllarda Walter (1957) teknik olarak mali yetersizliğin ölçümünü ele almış, mevcut nakit borçları ile ilgili net nakit akımlarının ilişkisini analiz etmiştir. Bu ilişkinin mali başarısızlığın teknik analizinde birincil kriter olması gerektiği yönündeki teoriyi geliştirmiştir. Walter mali yetersizliğin geçici bir durum olabileceğini, fakat iflas etmenin en büyük nedenleri arasında olduğunu belirtmiştir. Beaver (1966) yaptığı çalışmada ise tek değişkenli diskriminant analizini kullanmıştır. Mali başarısızlığa uğramış 79 şirket ile 79 başarılı şirketin verilerini örneklem olarak kullandığı çalışma sonucunda Nakit Akımı/Toplam Borç oranının finansal başarısızlığın öngörülmesi doğrultusunda en etkili oran olduğunu ortaya koymuştur. Beaver (1968) yaptığı diğer çalışmada ise, pay senedi verileri ile finansal oranları kullanmış, finansal başarısızlığın tahmini konusunda piyasa verilerinin dikkate alınamayabileceği sonucuna varmıştır. Yine aynı yıl yapılan bir çalışmada Altman (1968), Beaver (1966)'in yaptığı tek değişkenli diskriminant analizi yerine çoklu diskriminant analizini kullanmıştır. Veri seti olarak Beaver 79 başarılı 79 başarısız firmayı örneklem olarak alırken, Altman 33 başarılı ve 33 başarısız firmaların finansal

oranlarını almıştır. Yaptığı çalışmanın sonucunda literatürde önemli yer tutan Altman-Z skoru modelini bulmuştur. Finansal başarısızlıktan iki yıl önceden başarısızlığın öngörülebileceğini belirtmiştir. Edmister (1972) yaptığı çalışmada ise, küçük işletmelerin 6 yıllık, 7 ayrı finansal oranları kullanarak mali başarısızlığı öngörmeye çalışmıştır. Analiz sonucunda yüzde 90 oranında doğrulukla işletmeleri başarı ve başarısız olarak sınıflayabilmiştir. Diskriminant analizini finansal başarı durumunun tahmininde kullanan diğer bir araştırmacı olan Deakin (1972), yaptığı çalışmada, diğer çalışmalarda olduğu gibi örneklem grubunu iki eşit parçaya ayırmıştır. Örneklemini teşkil eden 64 işletmeyi 32 başarılı işletme, 32 başarısız şeklinde ayırıp, 3 yıl öncesine kadar finansal başarı durumlarını tahmin etmeye çalışmıştır. Diskriminant analizi sonucunda, başarısızlıktan 3 yıl önceki tahmin hatası düşük çıkmıştır. Sinkey ve Walker (1974) yaptıkları çalışmada ise farklı bir analiz yöntemini kullanmışlardır. 62 başarısız 62 başarılı işletmeyi varyans analiz metodu ile finansal başarı yönünden analiz etmişlerdir. Analiz sonucunda başarılı ve başarısız ayırımına tabi tutulan işletmeler arasında farklar bulunmuştur. İlerleyen yıllarda geçmişte uygulanan bazı yöntemlerin dezavantajları dikkate alınıp yeni metotlar kullanılmıştır. Bu metotlardan biri olan logit analizini Ohlson (1980) yaptığı çalışmada, başarılı ve başarısız şeklinde ayırdığı işletmelerin başarı durumunu tahmin etmek için kullanmıştır. Probit regresyon analiz modelini ise Zmijewski (1984) yaptığı çalışmada kullanmış, New York borsasında işlem gören firmaları analizine dahil etmiştir. Daha önceki çalışmalarda olduğu gibi başarılı ve başarısız firmaların örneklem sayılarının eşit olması durumunda modelin iyi bir performans göstereceğini açıklamıştır. Önceki araştırmalardan farklı olarak iki analiz metodunu uygulayan ve sınıflandırma da önemli oranları tespit etmeye çalışan Casey ve Bartczak (1985), başarılı ve başarısız firmaların 11 yıllık finansal verilerini lojistik regresyon ve çoklu diskriminant analizlerinde kullanmıştır. Analiz neticesinde nakit akımının doğru sınıflandırmada etkili olmadığı sonucuna varmıştır. Lojistik regresyonu kullanan diğer bir araştırmada Gilbert vd. (1990), başarılı ve başarısız firmaları tahmin etmeye çalışmışlardır. Analiz sonucunda lojistik regresyonun sınıflandırmada etkili olduğunu ortaya çıkarmışlardır. 90'lı yıllara gelince geleneksel istatistiki yöntemler ile beraber yapay zekâ yöntemleri de kullanılmaya başlanmıştır. Bahsedilen iki yöntemin beraber kullanıldığı çalışmaların birinde, Odom ve Sharda (1990) yapay sinir ağları ve diskriminat analizini kullanarak işletmelerin

başarısızlıklarını 1 yıl önceden öngörmeye çalışmışlardır. Yöntemlerin sınıflandırmada etkili olduğunu belirtmişlerdir. Pompe ve Feelders (1997) ise diğer çalışmalardan farklı olarak üç analiz yöntemi kullanarak yöntemlerin sınıflandırma performanslarını karşılaştırmışlardır. Çalışmalarında, liner diskriminat, yapay sinir ağı ve sınıflandırma ağaçları metotlarıyla Belçika'da faaliyet gösteren işletmelerin 40 finansal oranlarını kullanarak 1 yıl öncesinden başarısızlık durumlarını tahmin etmeye çalışmışlardır. Analiz sonucunda yapay sinir ağlarının tahmin gücünün daha iyi performans gösterdiğini ortaya çıkarmışlardır. Çoklu diskriminant analizini kullanan araştırmacılardan biri olan G. Zheng (2002) yaptığı çalışmada, ABD restoran firmalarının iflasını tahmin etmeye çalışmıştır. Model, örnek firmaların iflas eden ve iflas etmeyen gruplara sınıflandırılmasında yüzde 92'lik bir doğruluk oranına ulaşmıştır. Zheng ayrıca çalışmasında kullandığı bağımsız değişkenler içindeki oranlardan biri olan faiz ve vergi öncesi karın düşük olduğu işletmelerin iflase daha yakın olduğunu belirtmiştir.

Literatürde sınıflandırma problemlerinde sıkça kullanılan lojistik regresyon analizini Foreman (2003) yaptığı çalışmada kullanmıştır. ABD'de faaliyet gösteren iletişim sektöründeki firmaların 2 yıl önceden başarısızlıklarını lojistik regresyon analizi ile tahmin etmeye çalışmıştır. Başarılı işletmeleri %97,4 ve başarısız işletmeleri %86 oranında doğru sınıflandırmıştır. Foreman lojistik regresyonun sınıflandırmada güçlü bir yöntem olduğu sonucuna varmıştır. Makine öğrenmesi modellerinin kullanımı yıllar ilerledikçe artmıştır. Bu yöntemleri kullanan araştırmacılardan Koh ve Low (2004) yaptıkları çalışmada, 7 yıllık finansal verileri kullanarak, başarılı ve başarısız firmaları lojistik regresyon, karar ağacı ve yapay sinir ağı modelleri ile tahmin etmeye çalışmış ve analiz sonucunda karar ağacı modelinin en etkili model olduğu sonucuna varmıştır. Yapay sinir ağlarının kullanıldığı başka bir çalışmada, Nguyen (2005) çok katmanlı yapay sinir ağları, olasılıklı yapay sinir ağları ve lojistik regresyon modellerini kullanarak işletmelerin finansal başarısızlıklarını tahmin etmeye çalışmıştır. Çalışma sonucunda her üç model başarılı performans göstermiş olsa da en iyi performansı olasılıklı yapay sinir ağı modeli göstermiştir. Koh ve Low (2004)'un yaptıkları çalışmadan farklı olarak lojistik regresyon modeli yerine diskriminant analizi yöntemini çalışmalarında kullanan Chen vd. (2006), yapay sinir ağları, lojistik regresyon, karar ağaçları ve diskriminat analizi metotlarından, iki yıl öncesinden başarısız işletmeleri en doğru

sınıflandıran modelin yapay sinir ağı olduğu sonucuna varmışlardır. Yapay sinir ağı ve çoklu diskriminant analizini çalışmalarında kullanarak işletmelerin başarısızlığını tahmin etmeye çalışan Wu vd. (2008), yapay sinir ağı yöntemiyle işletmelerin başarısızlığa düşmeden bir yıl önceden %81,25, üç yıl önceden %81,3 tahmin oranları ile başarılı sonuç elde etmişlerdir. Genel olarak yapay sinir ağlarının diskriminant analizinin tahmin gücünden daha başarılı olduğunu ortaya koymuşlardır. Lee (2008) ise yaptığı çalışmada iflas tahmininde bulunmak için lojistik regresyon, yapay sinir ağı, CART, C5.0 ve karar ağaçları olmak üzere beş model oluşturmuş ve bu modellerin öngörü performanslarını karşılaştırmıştır. Karar ağacı modeli en yüksek doğruluk ve en düşük yanlış sınıflandırma yapmıştır. Sinan (2009) yaptığı çalışmada, ekonomideki tüm aktörler tarafından kullanılabilir bir finansal başarısızlık tahmin modeli geliştirmiştir. Mali başarısızlık kriterleri olarak Türk Ticaret Kanunu'nun 179. maddesi, Türk İflas Kanunu 324 ve 434. maddelerini ve önceki üç yılın her biri için net zararları kullanmıştır. İstanbul Menkul Kıymetler Borsasındaki 180 imalat firmasını 3 istatistiksel dağılım varsayımları ve piyasa temelli risk tahmini modellerini kullanmıştır. Çalışmada Merton modelleri ve muhasebe temelli modellerin sonuçları karşılaştırılmıştır. Test bulguları; KMV-Merton modellerinin muhasebe temelli modellerden üstün olmadığını, piyasa tabanlı ve muhasebe tabanlı modellerin sağlam ve nesnel bir erken uyarı sistemi oluşturulabileceğini göstermiştir. Amendola vd. (2017) yaptıkları çalışmalarında, iş dünyasındaki mali sıkıntı tahmin modellerinin, finansal sıkıntıları önlemek ve bir kriz anında tepki vermek, paydaşlara zamanında uyarı sağlamak açısından önemli olduğuna değinmişlerdir. Çalışmada, varsayımların karşılanmadığı durumlarda bile tutarlı olan Rodeo adlı parametrik olmayan bir metod kullanılarak ve ilgili değişkenleri seçerek bu limitlerin üstesinden gelinmesi önerilmektedir. Aynı zamanda yazarlar Rodeo'yu diğer iki değişken seçim yöntemiyle (Lasso ve Adaptive Lasso) karşılaştırmışlardır ve ampirik sonuçların, önerilen prosedürün pozitif / negatif yordayıcı değer açısından diğerlerini geride bıraktığını ve seçilen değişkenlerin doğrusal olmayan etkilerini yakalayabildiğini göstermişlerdir. İslami bankacılıkta yaygın olarak kullanılmayan, makine öğrenim tekniklerinden olan yapay sinir ağı yöntemini Anwar ve A.m (2018) bankalar üzerinde uygulamışlardır. İslami bankanın finansal oranları ve makroekonomik göstergeleri kullanarak finansal performansı konusunda Erken Uyarı Sistemi (EUS) modeli geliştirmişlerdir. Çalışma

YSA tekniđi kullanılarak üç ařamada gerekleřtirilmiřtir. Bunlar; finansal performansı önemli ölçüde etkileyen deđiřkenlerin seçimi, bir öngörücü olarak bir algoritma geliřtirilmesi ve örnek verilerden yola ıkararak tahmin algoritmasının test edilmesidir. Sonuç olarak, arařtırma, önerilen modelin sonraki iki ay boyunca İřlami bankanın mali kořullarını tahmin etmede %100 dođrulukla sonuçlandıđını göstermiřtir. Ngwenya (2018) yaptıđı alıřmada, 2011-2015 yılları arasında Güney Afrika'da listelenen altın ve platin madencilik řirketlerinin mali sıkıntısının durumunu deđerlendirmeyi amalamıřtır. Listede toplam 8 altın maden řirketi ve 11 platin madencilik řirketi mevcuttur. Analiz için bu řirketler arasından sadece 5 altın madencilik řirketi ve 5 platin madencilik řirketi seçilmiřtir. Örneklenen altın ve platin madencilik řirketlerinin standartlařtırılmıř finansal tabloları iNET BFA veri tabanından indirilerek, Altman Z-skoru ve Altman Z '(EM) puan modelleri finansal sıkıntılarını öngörmek için kullanılıp analiz edilmiřtir. Sonuçlar, altın madencilik řirketlerinin platin madencilik řirketlerinden daha fazla mali sıkıntıya sahip olduđunu ortaya koymuřtur. Sonuç olarak, altın ve platin madencilik řirketlerinin yönetiminin düzenli oran analizleri yapması ve řirketlerin finansal sađlıklarını iyileřtirmek için gerektiđinde düzeltici önlemler alması önerilmiřtir. Firmaların iflas ayrıntılarının mevcut olmadıđı Hindistan gibi geliřmekte olan bir ekonomide iřletmelerin iflas risklerini tahmin etmek için Shrivastava vd. (2018) modeller geliřtirmişlerdir. Bu amala Capital IQ'dan elde edilen veri seti kullanılmıřtır. alıřma, firmalara özgü parametrelerin bir kombinasyonunu kullanarak, Hint firmaları için yeni ortaya ıkan tehlike belirtilerini yakalamak için yeni bir çereve tasarlayarak katkıda bulunmaktadır. Analizde, Hint řirket sektöründeki sıkıntılı firmaları öngörmek için standart Lojistik ve Bayes modellemeleri kullanılmıřtır. Böylece, iki yaklařımın öngörü yeteneđinin bir karřılařtırması yapılmıřtır. Hem örneklem içi hem de örneklem dıřı deđerlendirmede, Bayes metodolojisi tutarlı bir řekilde daha iyi bir tahmin kabiliyetini ortaya koymaktadır. İřletmelerin ölçeklerine göre başarı durumlarının tahmin edilmesi için Gupta vd. (2018) alıřma yapmışlardır. Mikro, küçük ve orta ölçekli iřletmelerin iflas ve mali sıkıntılarının tahmin edilmesinde bu kuruluşların sahip oldukları farklılıkları ve büyüklükleri göz önüne almışlardır. Ampirik bulgular, firmaların hayatta kalma olasılıklarının artan firma büyüklüđü ile ilgili olduđudur. Aslında, finansal sıkıntılarını etkileyen faktörlerin çođunlukla deđiřmez olduđu bilinmektedir. Önemli deđiřkenlerin büyüklüđü, hem iflas etmiş

hem de finansal olarak sıkıntılı firmaların boyut kategorileri arasında değişmektedir. Ayrıca, işletmelerin gelir ve bilanço tabloları kullanılarak elde edilen risk tahmin modellemesinde, işletme nakit akışı bilgileri, çok değişkenli risk modellerinin performansında marjinal bir artış eklememiştir.

3.2. FİNANSAL BAŞARISIZLIK İLE İLGİLİ YURT İÇİ LİTERATÜR

Aktaş (1993) Türkiye’de ilk defa çok boyutlu modeller oluşturarak işletmelerin finansal başarısızlığını öngörmeye çalışmıştır. İşletmelerin mali tablolarını kullanarak oluşturduğu 23 oran ile 25 başarısız ve 35 başarılı işletmeyi analiz etmiştir. Çalışmasında doğrusal diskriminant, kuadratik diskriminant, çoklu regresyon ve lojistik ile probit regresyon analizlerini kullanarak modeller oluşturmuştur. Bağımsız değişken olarak kullandığı işletmelerin finansal oranları ile başarısız işletmeleri başarısızlıktan 1, 2, 3 yıl öncesinden tahmin etmeye çalışmıştır. Çalışma sonucunda Probit ve lojistik regresyon analizinin diskriminant ve çoklu regresyon analizine göre daha başarılı performans gösterdiğini ortaya koymuştur. Diskriminant analizini çalışmasında kullanan başka bir araştırmacı olan Ünsal (2001), finansal analizde ve planlamada geniş kullanımı olan finansal oranları kullanarak diskriminant analizi aracılığı ile Sermaye Piyasası Kurulu’na (SPK) bağlı mali başarılı şirketlerle, mali başarısız (iflas eden) şirketlerin ayrımını sağlayan diskriminat fonksiyonunu bulmaya çalışmıştır. Bunun için şirketlerin finansal tablolarından elde edilen 17 oran kullanılmıştır. Bu araştırmada, Sermaye Piyasası Kurumuna (SPK) bağlı, iflas eden veya tasfiye edilen (mali başarısız) toplam 43 şirketten analize uygun bilançooya sahip 16 şirket analize alınmıştır. Yine aynı kuruma bağlı faaliyetini sürdüren (mali başarılı) 848 şirket arasından tesadüfi seçilen 70 şirketten analize uygun bilançooya sahip 55 şirket analize dahil edilmiştir. Çalışmanın sonucunda başarısız işletmelerin doğru tahmin edilme oranı %81,3 olarak bulunmuştur. Örnekleme başarılı olarak dahil edilen 55 işletmenin ise hepsi doğru sınıflandırılmıştır. Oluşturulan modelin başarı ve başarısızlığı bir yıl önceden doğru tahmin etme olasılığı %95,77 olarak bulunmuştur. Kutman (2001) yaptığı çalışmada, Türkiye’de beyaz eşya, otomotiv ve gıda sektörlerindeki şirketlerin öz sermaye karlılıklarını bir sene öncesinden tahmin edebilecek bir model oluşturmuştur. Modelde, incelenen üç sektörde de etkili olabilecek ortak değişkenler

(finansal rasyolar ve ekonomik trendler) kullanılmıştır. Bahsedilen finansal oranlar ile ekonomik trendlerin hangilerinin, araştırmaya dahil edilen farklı sektörlerin başarısızlığına etki ettiğini bulmaya çalışılmıştır. Bu çalışmayı diğer çalışmalardan ayıran esas yönü başarısızlığın tespitine sektörel açıdan yaklaşımıdır. Çalışmanın sonucunda, her sektör için etkili olan rasyo oranlar ile ekonomik trendler belirlenmiştir. Sektörlerin farklılıkları nedeniyle mali başarısızlıklarının tespitinde kullanılan etkili değişkenler değişmektedir.

Literatürde analiz içermeyen sadece teorik olarak incelenen çalışmalar da mevcuttur. Bunlardan biri olan Uzun (2005) makalesinde finansal başarı/başarısızlığı teorik olarak araştırmıştır. Çalışmasında işletmelerin başarısızlığına neden olan faktörler ve başarısızlık çeşitleri açıklanmıştır. İşletmelerde başarısızlığı öngörmede kullanabilecek bazı modeller verilmiştir. Çakır (2005), maliyete duyarlı sınıflandırma ve sonuçları üzerinde önemle duran çalışmasında finansal baskı, firma başarısızlığı kuramları ve makine öğrenmesi yöntemlerini ele aldıktan sonra Merkez Bankası Reel Sektör Verileri Müdürlüğü veri tabanından alınan verilerle yaptığı ampirik uygulamalarla firma başarısızlığını incelemiştir.

İçerli ve Akkaya (2006) ise yaptıkları çalışmada işletmelerin mali anlamda başarılı ve başarısız olmalarının finansal oranlarla olan ilişkisini incelemişlerdir. Araştırmanın sonucuna göre asit-test oranı, cari oran ve alacak devir hızı oranlarında başarılı ve başarısız şeklinde iki sınıfa ayrılan gruplar arasında farklılıklar bulmuşlardır. Finansal açıdan başarısız olan işletmelerde negatif öz sermaye olması ve borç miktarının fazla oluşu varlıkların büyük bir kısmının yabancı kaynaklarla finanse edildiğini göstermektedir. Nakit oranı, aktif devir hızı, kısa vadeli yabancı kaynaklar/toplam aktifler, stok devir hızı ve karlılık oranları bakımından iki grup arasında önemli sayılabilecek fark elde edilememiştir. Ayrıca analiz sonucunda başarılı ve başarısız işletmeler arasında karlılık açısından bir fark bulunmamıştır. Genel anlamda en dikkat çekici sonuçlar, başarılı ve başarısız işletmeler arasındaki farklılıkların az olduğu, başarılı işletmelerin iyi bir yönetime sahip olmaması durumunda finansal açıdan başarısızlığa uğrayabilecekleri, başarısız işletmelerin ise, eğer yasal olarak iflas etmemişlerse, etkili bir yönetim ile finansal başarıyı yakalayabilecekleridir. Yapay sinir ağları yöntemini işletmelerin başarı durumunun tahmininden farklı olarak finansal bilgi manipülasyonunun tespitinde kullanan

Küçükkocaoğlu vd. (2007), finansal sıkıntıda bulunan firmaları tespit için kullanılan Yapay Sinir Ağı Modeli'nin finansal bilgi manipülasyonunun tespitine nasıl bir katkı sağlayacağını araştırmışlardır. Finansal bilgi manipülasyonunun tespiti için logit, probit ve çok değişkenli modeller kullanılmış ve bunların performansı yapay sinir ağları ile karşılaştırılmıştır. Çalışma sonucunda yapay sinir ağlarının diğer modellere kıyasla daha iyi sonuç verdiği görülmüştür. Literatürde başarısızlık tahmini için genelde 3 yıl öncesine kadar tahmin modelleri geliştirilmiştir. Torun (2007) ise yaptığı çalışmada, hisse senetleri borsada işlem gören 90 sanayi işletmesinin 1992-2004 yılları arası finansal oranlarını kullanarak, işletmelerin finansal başarısızlığını çok değişkenli diskriminant analizi, lojistik regresyon analizi ve yapay sinir ağları yöntemi ile başarısızlığı 5 yıl öncesine kadar tahmin etmeye çalışmıştır. Elde ettiği sonuçlar ile kullanılan metodların performanslarını karşılaştırmıştır. Karşılaştırma sonucuna göre, başarısızlıktan bir ve iki yıl öncesi için en iyi tahmin gücüne sahip model yapay sinir ağları yöntemi olmuştur. Yapay sinir ağlarını çalışmada kullanan bir başka yazar Çelik (2009), borsada hisseleri bulunan firmaların 1992-2008 yılları arasındaki finansal tablolarını kullanarak oluşturulan oranları kullanarak, başarısızlığı 1, 2 ve 3 yıl önceden tahmin etmeye çalışmıştır. Çalışmada tahmin modelleri için Altman'ın Z puan modeli, diskriminant analizi ve yapay sinir ağını kullanmıştır. Çalışma sonucunda yapay sinir ağları tekniğinin diğer modellere göre daha iyi performans gösterdiğini ortaya koymuştur.

Ergin (2009) yaptığı çalışmada, borsada işlem gören 308 işletmenin verileri, Black Scholes-Merton (BSM) opsiyon modeli ile Z-Skor modelini kullanarak başarısızlık tahmininde bulunmuştur. Kullanılan tüm modellerin doğru tahmin etme gücü istatistiksel olarak yüksektir. Modellere ait sonuçlar, özellikle tıp alanında kullanılan işlem karakteristiği eğrisi yardımıyla karşılaştırıldığında, muhasebe temelli geleneksel modellerin, pazar temelli opsiyon modellerine üstün olduğunu ortaya koymaktadır. Kılıç ve Seyrek (2012) yaptıkları çalışmada ise, borsada işlem gören imalat sanayi sektöründeki işletmelerin 2005-2010 yıllarına ait 12 aylık mali tablolarını kullanarak başarısızlığı önceden tahmin etmişlerdir. Tahmin modeli için yapay sinir ağlarından yararlanılmıştır. Modelin bağımsız değişkenleri ise işletmelerin finansal oranlarıdır. Çalışma sonucuna göre, finansal başarısızlığı etkileyen en önemli değişken faaliyet karlılığı oranıdır. Yapay sinir ağlarının tahmin performansı %84 olarak bulunmuştur. Yapay zekâ modellerini kullanan bir

çalışmasında Akgün (2013), borsada işlem gören 130 sanayi firmasının 2008-2010 yılları arasındaki finansal tabloları ile elde edilen oranları kullanarak tahmin modelleri oluşturmuştur. Finansal başarısızlık tahminlerinde yapay zekâ modelleri olan Ardışık Yinelemeli Ağ Bulanık Çıkanın Sistemi (ANFIS) ve Yapay Bağışıklık Tanıma Sistemi (AIRS) modelleri kullanılmıştır. Finansal oranlar, Altman'ın analizde kullandığı ve Z-skor ve Zeta analizi olarak adlandırılan oranlardan elde edilmiştir. Seçilen işletmeler için başarısızlık kriterleri olarak işlem sırasının kapatılması ve üç yıl üst üste zarar etmiş olma seçilmiştir. Yapılan analiz sonucunda finansal başarısızlık 1, 2 ve 3 yıl önceden tahmin edilmiştir. Çalışmanın sonucunda ANFIS modelinin YBTS'ye göre yüksek sınıflandırma başarısına ulaşmasından dolayı finansal başarısızlık tahmininde ANFIS modelinin kullanılmasının uygun olduğu sonucuna varılmıştır. Sadece bir yıl öncesinden işletmelerin başarı durumunu tespit etmeye çalışan Salur (2015), 2008-2013 yılları arasında BİST'te işlem gören işletmelerin mali tablolarını kullanarak yapay sinir ağları metodu ile başarısızlık tahmininde bulunmuştur. Yapay sinir ağları modeli çok katmanlı ileri beslemeli ve geri yayılım algoritması kullanılarak oluşturulmuştur. İşletmelerin önceden belirli kriterlere göre belirlenen başarı durumu ile yapay sinir ağı modelinin üretmiş olduğu tahmin sonuçları 0,50 kopuş değeri üzerinden karşılaştırılmıştır. Çalışmanın sonucunda yapay sinir ağları modelinin seçilen finansal başarısızlığı tahmin etmede yüksek bir performans gösterdiği görülmüştür. Yapay sinir ağlarını teorik olarak inceleyen başka bir çalışmada Söylemez ve Türkmen (2017), uluslararası literatürün etkin bir taramasını gerçekleştirmiş ve finansal başarısızlık ile ilgili yapılacak çalışmalarda kullanılacak yol gösterici bir kaynak oluşturmuşlardır.

DÖRDÜNCÜ BÖLÜM

YAPAY ZEKÂ YÖNTEMLERİ İLE İŞLETMELERİN FİNANSAL BAŞARISIZLIĞININ TAHMİN EDİLMESİ: BİST İMALAT SEKTÖRÜ UYGULAMASI

4.1. MATERYAL VE YÖNTEM

Çalışmada, Borsa İstanbul'da (BİST) işlem gören imalat sanayi sektörlerindeki işletmelerin 2008-2016 yılları arasındaki verileri esas alınmıştır. İmalat sanayii sektörleri, ülke ekonomisi açısından en önemli sektörler arasındadır. Türkiye İstatistik Kurumu (TÜİK) 2017 yılına ilişkin girişim özelliklerine göre dış ticaret istatistikleri verilerinde girişimin ana faaliyetine göre ihracatın yüzde 56,6'sı, ithalatın ise yüzde 52,1'i sanayi sektöründe faaliyet gösteren girişimler tarafından yapılmıştır. Ana faaliyeti ticaret olan girişimlerin ihracattaki payı yüzde 40, ithalattaki payı ise yüzde 34,1 düzeyinde hesaplanmıştır (TÜİK, 2017). İhracatın yarısından fazlasını imalat sanayii sektörleri gerçekleştirmiştir.

Ülke çapındaki tüm sanayi işletmelerinin verilerini elde etmek mümkün değildir. Borsa İstanbul'da hisseleri işlem gören firmaların, finansal raporları denetimden geçip borsaya sunulmakta ve Kamuyu Aydınlatma Platformu'nun (KAP) kurumsal resmi web sitesinde ilan edilmektedir. Bu nedenle çalışmada kullanılan veriler bağımsız denetçilerin kontrolünden geçmiş ve KAP'ta sunulan 12 aylık finansal tablolardan ve raporlardan elde edilmiştir.

Bu çalışmaya alınan işletmelerin KAP'ta belirtilen faaliyet sektörleri; gıda, içki ve tütün sektörü, dokuma, giyim eşyası ve deri sektörü, orman ürünleri ve mobilya sektörü, kâğıt, kâğıt ürünleri, basım ve yayın sektörü, kimya, petrol, kauçuk ve plastik ürünleri sektörü, taş ve toprağa dayalı sanayi sektörü, metal ana sanayi sektörü, metal eşya, makine ve gereç yapımı sektörü, diğer imalat sektörleri, elektrik, gaz ve su sektörü ve inşaat sektörüdür.

Borsa İstanbul'da işlem gören sanayi işletmelerinin 2008-2016 yılları arasında toplam sayısı 181'i geçmediğinden, sektör bazlı tahmin modeli kurulmamıştır. Sanayi işletmelerinin tümü sektörel ayrıma tabi tutulmadan analize dahil edilmiştir. Bu çalışmada 2008-2016 yılları arasında Borsa İstanbul'da (BİST) işlem gören ya da daha önce işlem görmüş sanayi işletmelerinin mali tablo ve raporlarından yararlanılmıştır. Bahsedilen işletmelerin finansal tabloları BİST, KAP ve SPK'nın kurumsal web sitelerindeki veri tabanından elde edilmiş ve değerlendirilmiştir. Torun (2007) ve Aksoy (2018)'un çalışmalarında belirtildiği gibi, işletme ile ilgili kararlarda iki yıllık bir sürenin yeterli olması ve 3 yıldan sonraki tahmin modellemesinde sınıflandırma hatalarının artmasından dolayı daha geriye tahmin modellemesi oluşturmanın faydası olmayacaktır. Bu nedenle çalışmada 3 yıldan geriye tahmin modellemesi oluşturulmamıştır.

Örnekleme dahil edilen işletmeler 2008-2016 yılları arasında en az üst üste 4 yıl işlem gören ve finansal tablolarına ulaşılabilen işletmelerdir. 2005 ve 2006 yıllarında başarılı olmuş ancak 2007 yılında başarısız bir işletmenin, başarılılığından 3 yıl önceki yılı 2004 olduğundan, başarısızlık başlangıç yılı 2008 olarak belirlenmiştir. Sermaye Piyasası Kurulu'nun Uluslararası Finansal Raporlama Standartları (UFRS) uyumlu Seri: XI, No: 25 sayılı "Sermaye Piyasasında Muhasebe Standartları Hakkında Tebliğ'i, 15.11.2003 tarih ve 25290 Mükerrer sayılı Resmi Gazete'de yayınlanarak yürürlüğe girmiştir. Resmi Gazetede yayınlanan tebliğ kapsamında yer alan şirketlerin, 01.01.2005 tarihini izleyen ilk ara mali tablolarından itibaren bu standartlara uyma zorunluluğu getirilmiştir. 2005 yılı öncesi mali tablolarla, 2005 yılı sonrası mali tabloların standartları farklı olduğundan ve bu farklılık oransal hatalara neden olacağından 2005 yılı öncesinden veri alınmamıştır. Bu nedenle başlangıç yılı 2008 olarak seçilmiştir.

Modellerinin kurulmasında IBM SPSS MODELER 18.0 bilgisayar yazılımından yararlanılmıştır. Literatürde; eğitim, onaylama ve test gruplarının belirlenmesinde (%80,%10,%10), (%70,%15,%15), (%60,%20,%20) oranlarında ayırım yapılırken, (%70,%30), (%80,%20), (%60, %40) oranlarında Eğitim ve Test şeklinde bölümlendirmeler de yapılmıştır. Bu çalışmaya dahil edilen BİST İmalat sanayi sektöründeki işletme sayısının çok fazla olmamasından dolayı modele dahil

edilecek işletmelerin bölümlendirilmesi, Eğitim ve Test şeklinde ayrılmış, onaylama seti kullanılmamıştır. Verilerin %60'ı eğitim, %40'ı ise test için kullanılmıştır.

4.2. KULLANILAN DEĞİŞKENLER

İşletmelerin finansal başarısızlığını tahmin etmek için oluşturulan modellerin büyük çoğunda bağımsız değişken olarak sık kullanılan ve başarısızlığı tahmin etmede önemli sayılan oranlar kullanılmıştır. Bu çalışmada Akkaya vd. (2009), Torun (2007), Kılıç ve Seyrek (2012)'in analizlerinde olduğu gibi benzer 26 finansal oran kullanılmıştır (Tablo 4.1).

Tablo 4.1. Kullanılan Finansal Oranlar

Kod	
X1	Cari Oran
X2	Asit-Test Oranı
X3	Nakit Oran
X4	Stokların Toplam Varlıklara Oranı
X5	Kısa Vadeli Alacakların Toplam Varlıklara Oranı
X6	Stoklar/Dönen Varlıklar
X7	Finansal Kaldıraç Oranı
X8	Kısa V.Yabancı Kaynakların Toplam Kay.Oranı
X9	Uzun Vadeli Yab.Kaynakların Top.Kay.Oranı
X10	Uzun Vadeli Yab Kaynakların Devamlı Sermayeye Oranı
X11	Duran Varlıkların Öz sermayeye Oranı
X12	Dönen Varlıkların Toplam Varlıklara Oranı
X13	Hazır Değerler Devir Hızı
X14	Stok Devir Hızı
X15	Alacak Devir Hızı
X16	Dönen Varlık Devir Hızı
X17	Öz sermaye Devir Hızı
X18	Toplam Varlık Devir Hızı
X19	Öz sermayenin Karlılığı Oranı
X20	FVÖK Toplam Kaynaklara Oranı
X21	Toplam Varlıkların Karlılığı Oranı
X22	Faaliyet Kar Marjı
X23	Brüt Kar Marjı
X24	Duran Varlıklar Devir Hızı
X25	Net Kar Marjı
X26	Finansman Giderlerinin Net Satışlara Oranı

4.3. FİNANSAL BAŞARISIZ İŞLETMELERİN SINIFLANDIRILMA ÖLÇÜTLERİ

İşletmelerin finansal başarısızlığının önceden tahmini için geliştirilen analizlerde, en önemli konu, çalışmaya dahil edilen işletmelerin hangi ölçütlere göre başarısız sayılması hususudur. Literatürde bu konudaki sınıflandırma ölçütleri incelendiğinde birçok sınıflandırma görülmektedir. Türkiye’de yapılan çalışmalarda daha çok işletmenin iflas durumu ve son yıllardaki finansal tablolarındaki zarar durumu dikkate alınarak başarısız işletme kategorisine eklendiği görülmektedir (Kılıç ve Seyrek, 2012; Salur, 2015: 96). İşletmeleri başarısız sınıfına eklerken seçilen başarısızlık tanımı, finansal başarısızlığın önceden tahmini için oluşturulan modelin doğruluk performansını etkilemektedir. Bu çalışmada analize dahil edilen başarısız firmalar aşağıdaki gibi beş şekilde sınıflandırılmıştır:

- İflas
- BİST yakın izleme pazarında yer almak
- Faaliyetlerini durdurmuş olmak
- İki yıl üst üste zarar etmiş olmak
- Aktif tutarının %10’unu kaybetmiş olmak (dönem ve geçmiş yıllar zararlarının aktif toplamının %10’u bulması).

Yukarıdaki sınıflandırma kriterlerinden bir veya birden fazla kritere uyan işletme başarısız sayılmış ve başarısızlığın başladığı ilk başlangıç yılı (t) olarak belirlenmiştir. Başarısız kategorisine eklenen bu işletmeler (t-1), (t-2) ve (t-3) yıllarında normal faaliyetlerine devam ederken (t) yılında başarısızlığa uğrayan işletmelerdir. Çalışmadaki asıl amaç (t) yılında başarısız olan bu işletmelerin (t-1), (t-2) ve (t-3) yıllarında yani başarısızlığa uğramadan, erken tahmin edilebilirlik durumudur. Bunun dışında analize dahil edilen işletmelerden, yukarıdaki kriterlere uymayan ve tüm yıllarda faaliyetlerine devam eden diğer işletmeler başarılı işletme sınıfına eklenmiştir. Bahsedilen tüm durumlar dikkate alınarak yıllara göre başarısız işletmelerin sınıflandırılması yapılmış ve Tablo 4.2’de gösterilmiştir.

Tablo 4.2. Yıllara Göre Başarısız İşletmelerin Sayısı

YIL	SAYI
2016	7
2015	15
2014	10
2013	7
2012	6
2011	8
2010	7
2009	3
2008	7
TOPLAM	70

4.4. ÖRNEKLEM

Tablo 4.2’de görüldüğü üzere belirlenen kriterler doğrultusunda 70 şirket başarısız olarak belirlenmiştir. İmalat sektöründeki 2008-2016 yılları arasındaki 181 şirketten finansal tablolarında eksiklik olan ya da bu araştırmanın yılları arasına girmeyen 30 firma araştırma kapsamı dışında bırakılmıştır. İşlem gören şirketlerden 50, iflas/kottan çıkma/ işlem sırası kapatılan 20 firma araştırmaya alınarak toplam 70 firma başarısız, geriye kalan 101 firma ise başarılı olarak değerlendirilmiştir. Çalışma için belirlenen başarısız veya başarılı örnek kriterlerine uymayan veya bu kritere uydukları halde bazı yıllarda mali tablo kalemlerinden bazıları eksik olan işletmeler de örneklem dışı bırakılmıştır. Literatürde analize giren başarılı ve başarısız firmaların sayısının eşit olmaması durumunda hatalı sonuçlar meydana geldiği görülmektedir. Bu hataların önüne geçmek için Çelik (2009), Aksoy (2018) ve Öcal ve Kadioğlu (2015)’nin çalışmalarında olduğu gibi her iki grubun örnek içinde eşit sayıda temsil edilmesini sağlamak amacıyla, tesadüfi olarak başarılı işletmelerden 31’i kapsam dışı bırakılmıştır. Dolayısıyla, uygulamada kullanılan örnek, yarısı başarısız, yarısı başarılı olmak üzere 140 sanayi işletmesinden oluşmaktadır.

Yıllara göre başarısız firma sayısının tespiti yapılırken en fazla başarısızlığın 15 firma ile 2015 yılında olduğu Tablo 4.2’de görünmektedir. Yakut (2012) ve Aksoy (2018) çalışmalarında olduğu gibi bu çalışmada da başarısız firma sayısının 2015 yılında en fazla olmasından dolayı başarılı firmaların finansal oranları hesaplanırken 2015 yılı baz yılı olarak seçilmiştir.

4.5. UYGULAMA-BULGULAR

Bu bölümde YSA, DVM ve Ensemble (topluluk) öğrenme modelleri oluşturulmuş ve performans karşılaştırılması yapılmıştır.

4.5.1. Yapay Sinir Ağları ile oluşturulan modelin değerlendirilmesi

Bu bölümde finansal başarısızlığın önceden tahmini için oluşturulan Yapay Sinir Ağları modelinin sınıflandırma doğruluğu incelenecektir. Modelin, işletmenin başarısızlığa uğramadan 1, 2 ve 3 yıl öncesinden tahmin performansı araştırılacaktır. Yapay sinir ağı modellemesinde gizli katmanda bulunan nöron sayısı her problemin yapısından ve içerdiği veri setinin farklılığından dolayı değişmektedir. Gizli katmandaki nöron sayısının tespiti oldukça fazla denemeler sonucu belirlenmektedir. Çalışmada gizli katmandaki nöron sayısının belirlenmesi deneme yanılma sonucu en yüksek doğruluğu tespit edilene kadar devam etmiştir. Bu çalışmada 2-35 arası nöron kullanılarak en uygun YSA modeli oluşturulmaya çalışılmıştır. Oluşturulan ağ çok katmanlı YSA modeli olup danışmalı öğrenme sınıfına girmektedir.

4.5.1.1. Başarısızlıktan bir yıl önce (t-1) dönemi için YSA analiz sonuçları

İşletmelerin başarısızlığa uğradığı t yılından önceki yıl olan (t-1) yılında işletmelerin başarısızlık durumunun tespiti için oluşturulan YSA 2 gizli katmandan oluşmuştur. 1. gizli katman 22 nöron, 2. gizli katman 10 nöron oluşmaktadır. Ağın aktivasyon fonksiyonu için lineer, sigmoid, sinüs, step, eşik değer ve hiperbolik tanjant aktivasyon fonksiyonları içinde en uygun performansı gösteren hiperbolik tanjant fonksiyonu kullanılmıştır. Model çalıştığında elde edilen çıktı Tablo 4.3'de gösterilmiştir. Tablo 4.3'de görüldüğü üzere (t-1) dönemi için modelimiz eğitim seti için rastgele ayrılan 81 işletmeden başarısız olan 41 işletmenin 33'ünü doğru sınıflandırmış, geriye kalan 40 başarılı işletmeden 29 işletmeyi doğru sınıflandırmıştır. Eğitim seti için toplam sınıflandırma doğruluğu %76,54 bulunmuştur. Test seti için sınıflandırma doğruluğu incelenirse, toplam 59 işletme için yapılan sınıflandırmada başarısız olan 29 işletmeden 24'ü, gerçekte başarılı olan 30 işletmenin 23'ü doğru sınıflandırılmıştır. Test seti için toplam sınıflandırma doğruluğu ise %79,66 bulunmuştur.

Tablo 4.3. (t-1) Dönemi İçin Oluşturulan YSA Modelinin Özellikleri ve Sınıflandırma Matrisi

Yapay Sinir Ağı Modeli		Çok Katmanlı	
1.Gizli Katmandaki Nöron Sayısı		22	
2.Gizli Katmandaki Nöron Sayısı		10	
Aktivasyon Fonksiyonu		Hiperbolik Tanjant	
YAPAY SİNİR AĞI MODELİ EĞİTİM SETİ İÇİN SINIFLANDIRMA MATRİSİ (t-1 dönemi)			
		Gerçek Grup	
		Başarısız İşletmeler	Başarılı İşletmeler
Tahmin Edilen Grup	Başarısız İşletmeler	33	8
	Başarılı İşletmeler	11	29
	Toplam Sınıflandırma Doğruluğu = (33+29)/81 = % 76,54		
YAPAY SİNİR AĞI MODELİ TEST SETİ İÇİN SINIFLANDIRMA MATRİSİ (t-1 dönemi)			
		Gerçek Grup	
		Başarısız İşletmeler	Başarılı İşletmeler
Tahmin Edilen Grup	Başarısız İşletmeler	24	5
	Başarılı İşletmeler	7	23
	Toplam Sınıflandırma Doğruluğu = (24+23)/59 = % 79,66		

İşletmelerin başarısızlık durumunun tespiti için oluşturulan YSA modelinin girdileri olan değişkenler işletmeleri sınıflandırmada farklı değerlerde etki göstermektedir. Tablo 4.4’de işletmelerin başarısızlığa uğradığı t yılından önceki yıl olan (t-1) yılında oluşturulan YSA modelindeki değişkenlerin, sınıflandırmada gösterdikleri etki değerleri gösterilmiştir. Tabloda modelde en etkili ilk 10 değişken gösterilmiştir. Tabloda da belirtildiği gibi ilk sırada X21 ile kodlanan ve modele girdi olan değişken “Toplam Varlıkların Karlılığı Oranı”dır. Daha sonra sırasıyla aralarında çok fazla değer farkı olmaksızın, X7,X26,X20,X13,X1,X17,X15,X25 ve X2 değişkenleridir.

Tablo 4.4. YSA Modeli İçin (t-1) Yılına Ait Önemli Değişkenler

	Değişken	Değer	
1	X21	0,0815	X21
2	X7	0,0622	X7
3	X26	0,0619	X26
4	X20	0,0581	X20
5	X13	0,0575	X13
6	X1	0,0563	X1
7	X17	0,0527	X17
8	X15	0,0472	X15

9	X25	0,0461	
10	X2	0,0453	

Tablo 4.4’de görüldüğü üzere modelin hesaplanmasında yer alan en önemli oranların değerleri birbirine çok yakındır. Yani modelimiz çıktı değerini oluştururken oranlar yakın derecede katkı sağlamıştır. Her ne kadar yakın değerler olsa da X21 oranı yani toplam varlıkların karlılığı oranı tabloda ilk sırada yer almıştır. Aktif karlılık veya yatırım getirisi şeklinde de adlandırılan toplam varlıkların karlılığı oranı; net dönem karı veya zararının, toplam varlıklara bölünmesiyle elde edilmiştir. Bu oran, şirketlerin gerçekleştirmiş olduğu yatırımın karlılığını, diğer bir ifade ile varlıklarını ne ölçüde verimli kullandığını göstermektedir. Ayrıca şirket yönetiminin varlıklarını kazanç elde etmek için ne şekilde kullandığı konusunda fikir verebilir. Hesaplanan oran ne kadar büyük ise şirketin kar yaratma konusunda o derece başarılı olduğu sonucunu çıkarabiliriz. Aktif karlılık sonuçları, yatırımcılara, yatırım yapacağı şirketin kar yaratma becerisi hakkında bilgi verir. Aktif karlılığı yüksek olan şirket daha az yatırımla daha fazla para kazanma ihtimaline sahiptir ve dolayısıyla hissedarlarına daha fazla kar payı dağıtabilecektir (Businessht, 2017). Bir şirketin aktif yapısı faaliyet gösterdiği sektöre göre değişebilir. Bazı sektörlerde likit varlıklar daha yoğunken, bazı sektörlerde ise taşınmazlar daha fazladır. Bu çalışmanın kapsamını teşkil eden imalat sanayisi şirketlerinin de bilançosunda makine teçhizat gibi kalemler daha ağırlıklıdır. Onun için bu oranın sanayi şirketlerinde düşük çıkması muhtemeldir. Bu oranı doğru değerlendirmek için şirketin bir önceki yıldaki oran değeri ve sektördeki diğer şirketlerin aktif karlılık oranları ile karşılaştırmak gerekir.

4.5.1.2. Başarısızlıktan iki yıl önce (t-2) dönemi için YSA analiz sonuçları

İşletmelerin başarısızlığa uğradığı t yılından 2 yıl önceki yıl olan (t-2) yılında işletmelerin başarısızlık durumunun tespiti için oluşturulan YSA 2 gizli katmandan oluşmuştur. 1. ve 2. gizli katmanda 30’ar nöron bulunmaktadır. Ağın aktivasyon fonksiyonu (t-1) yılı için oluşturulan ağ modelindeki gibi, hiperbolik tanjant fonksiyonu olarak belirlenmiştir. Model çalıştığında elde edilen çıktı Tablo 4.5’de gösterilmiştir. Tablo 4.5’de görüldüğü üzere (t-2) dönemi için modelimiz eğitim seti için rastgele ayrılan 81 işletmeden başarısız olan 41 işletmenin 34’ünü

doğru sınıflandırmış, geriye kalan 40 başarılı işletmeden 37 işletmeyi doğru sınıflandırmıştır. Eğitim seti için toplam sınıflandırma doğruluğu %87,65 bulunmuştur. Buradaki tahmin gücü oldukça yüksektir. Bu durumlarda test seti verilerinin çıktılarını dikkate alınarak performans değerlendirilmesi yapılmalıdır. Test seti için sınıflandırma doğruluğu incelenirse, toplam 59 işletme için yapılan sınıflandırmada başarısız olan 29 işletmeden 23'ü, gerçekte başarılı olan 30 işletmenin 22'si doğru sınıflandırılmıştır. Test seti için toplam sınıflandırma doğruluğu ise %76,27 bulunmuştur.

Tablo 4.5. (t-2) Dönemi İçin Oluşturulan YSA Modelinin Özellikleri ve Sınıflandırma Matrisi

Yapay Sinir Ağı Modeli		Çok Katmanlı	
1.Gizli Katmandaki Nöron Sayısı		30	
2.Gizli Katmandaki Nöron Sayısı		30	
Aktivasyon Fonksiyonu		Hiperbolik Tanjant	
YAPAY SİNİR AĞI MODELİ EĞİTİM SETİ İÇİN SINIFLANDIRMA MATRİSİ (t-2 dönemi)			
		Gerçek Grup	
		Başarısız İşletmeler	Başarılı İşletmeler
Tahmin Edilen Grup	Başarısız İşletmeler	34	7
	Başarılı İşletmeler	3	37
	Toplam Sınıflandırma Doğruluğu = (40+34)/81 = % 87,65		
YAPAY SİNİR AĞI MODELİ TEST SETİ İÇİN SINIFLANDIRMA MATRİSİ (t-2 dönemi)			
		Gerçek Grup	
		Başarısız İşletmeler	Başarılı İşletmeler
Tahmin Edilen Grup	Başarısız İşletmeler	23	6
	Başarılı İşletmeler	8	22
	Toplam Sınıflandırma Doğruluğu = (22+23)/59 = % 76,27		

Tablo 4.6'da işletmelerin başarısızlığa uğradığı t yılından önceki yıl olan (t-2) yılında oluşturulan YSA modelindeki değişkenlerin, sınıflandırmada gösterdikleri etki değerleri gösterilmiştir. Tabloda YSA modelinde işletmelerin sınıflandırılmasında en etkili ilk 10 değişken gösterilmiştir. Tabloda da belirtildiği gibi ilk sırada X9 ile kodlanan ve modele girdi olan değişken "Uzun Vadeli Yab.Kaynakların Top.Kay.Oranı" dır. Daha sonra sırasıyla X21,X26,X4,X2,X12,X17,X14,X1 ve X25 kodlu değişkenlerdir.

Tablo 4.6. YSA Modeli için (t-2) Yılına Ait Önemli Değişkenler

	Değişken	Önem Değeri
1	X9	0,0794
2	X21	0,0742
3	X26	0,0716
4	X4	0,0504
5	X2	0,049
6	X12	0,0488
7	X17	0,0483
8	X14	0,0441
9	X1	0,0414
10	X25	0,0399

Tablo 4.6’da görüldüğü üzere (t-2) dönemi için oluşturulan modelin çıktı değerlerinin hesaplanmasında en etkili oran X9, uzun vadeli yabancı kaynakların, pasif toplamına bölümünden elde edilmiştir. Varlıkların ne kadarlık kısmının uzun vadeli yabancı kaynaklarla karşılandığını gösterir. Şirketler genellikle uzun vadeli yabancı kaynak elde etmedeki güçlükler nedeniyle bu oran, özellikle sanayi şirketleri için daha anlamlıdır. Çok fazla uzun vadeli kaynak kullanımı, yıllık faiz yükünü artırır, hissedarların kar payını azaltır ve şirketler kriz veya durgunluk dönemlerinde kredi borç taksitlerini ödeyemez duruma gelip temerrüt durumuna düşebilirler. Satışları istikrarlı ve uzun süredir aynı iş kolunda faaliyet gösteren şirketler ile sermaye yoğun teknoloji kullanan şirketlerin oranının yüksekliği kabul edilir (Gençoğlu, 2014: 98).

4.5.1.3. Başarısızlıktan üç yıl önce (t-3) Dönemi İçin YSA Analiz Sonuçları

İşletmelerin başarısızlığa uğradığı t yılından 3 yıl önceki yıl olan (t-3) yılında işletmelerin başarısızlık durumunun tespiti için oluşturulan YSA 2 gizli katmandan oluşmuştur. 1. gizli katman 17 nöron; 2. gizli katman 12 nöron

oluşturmaktadır. Bu oluşturulan ağıın aktivasyon fonksiyonu da hiperbolik tanjant fonksiyonu olarak belirlenmiştir. Model çalıştığında elde edilen çıktı Tablo 4.7’de gösterilmiştir. Tablo 4.7’de görüldüğü üzere (t-3) dönemi için modelimiz eğitim seti için rastgele ayrılan 81 işletmeden başarısız olan 41 işletmenin 37’sini doğru sınıflandırmış, geriye kalan 40 başarılı işletmeden 34 işletmeyi doğru sınıflandırmıştır. Eğitim seti için toplam sınıflandırma doğruluğu %87,65 bulunmuştur. Test seti için sınıflandırma doğruluğu incelenirse, toplam 59 işletme için yapılan sınıflandırmada başarısız olan 29 işletmeden 21’i, gerçekte başarılı olan 30 işletmenin de 23’ü doğru sınıflandırılmıştır. Test seti için toplam sınıflandırma doğruluğu ise %74,58 bulunmuştur.

Tablo 4.7. (t-3) Dönemi İçin Oluşturulan YSA Modelinin Özellikleri ve Sınıflandırma Matrisi

Yapay Sinir Ağı Modeli		Çok Katmanlı	
1.Gizli Katmandaki Nöron Sayısı		17	
2.Gizli Katmandaki Nöron Sayısı		12	
Aktivasyon Fonksiyonu		Hiperbolik Tanjant	
YAPAY SİNİR AĞI MODELİ EĞİTİM SETİ İÇİN SINIFLANDIRMA MATRİSİ (t-3 dönemi)			
		Gerçek Grup	
		Başarısız İşletmeler	Başarılı İşletmeler
Tahmin Edilen Grup	Başarısız İşletmeler	37	4
	Başarılı İşletmeler	6	34
	Toplam Sınıflandırma Doğruluğu = (37+34)/81 = % 87,65		
YAPAY SİNİR AĞI MODELİ TEST SETİ İÇİN SINIFLANDIRMA MATRİSİ (t-3 dönemi)			
		Gerçek Grup	
		Başarısız İşletmeler	Başarılı İşletmeler
Tahmin Edilen Grup	Başarısız İşletmeler	21	8
	Başarılı İşletmeler	7	23
	Toplam Sınıflandırma Doğruluğu = (21+23)/59 = % 74,58		

Tablo 4.8’de işletmelerin başarısızlığa uğradığı t yılından önceki yıl olan (t-3) yılında oluşturulan YSA modelindeki değişkenlerin, sınıflandırmada gösterdikleri etki değerleri gösterilmiştir. Tabloda YSA modelinde işletmelerin sınıflandırılmasında en etkili ilk 10 değişken gösterilmiştir. Tabloda da belirtildiği gibi ilk sırada X21 ile kodlanan ve modele girdi olan değişken “Toplam Varlıkların Karlılığı Oranı”dır. Daha sonra sırasıyla aralarında çok fazla değer farkı olmaksızın, X8,X18,X15,X25,X13,X7,X26,X20 ve X24 kodlu değişkenlerdir.

Tablo 4.8. YSA Modeli için (t-3) Yılına Ait Önemli Değişkenler

	Değişken	Önem Değeri
1	X21	0,0723
2	X8	0,0641
3	X18	0,06
4	X15	0,0569
5	X25	0,055
6	X13	0,0439
7	X7	0,0433
8	X26	0,0411
9	X20	0,0404
10	X24	0,0389

Tablo 4.8’de görüldüğü gibi (t-1) döneminde olduğu gibi (t-3) döneminde de X21 oranı modelin sonuç üretmesinde en etkili oran olmuştur. X21 oranı (t-1) döneminde açıklandığı gibi şirketlerin varlıklarını ne derece verimli kullanıp kar ettikleri hakkında fikir veren bir orandır. Önemli bir oran olup diğer sanayi işletmelerinin oranları ile mukayese yapılması ile daha anlamlı olacaktır.

4.5.2. Destek vektör makineleri ile oluşturulan modelin değerlendirilmesi

Destek vektör makineleri ile başarısızlık tahmininde YSA’da olduğu gibi verilerin %60’ı eğitim %40’ı ise test için ayrılmıştır. DVM tahmin modellemesi için IBM SPSS Modeler 18.0 versiyon paket program kullanılmıştır. Programa bağımsız değişkenler tanımlanmıştır. Destek Vektör Makinelerinde, doğrusal (linear), polynominal, Radial Basis Function (RBF) ve sigmoid gibi çeşitli çekirdek fonksiyonları mevcuttur. Bu çalışmada tüm çekirdek fonksiyonları denenmiş ve en iyi performansı gösteren kernel fonksiyonu olan Radial Basis Function (RBF)

kullanılmıştır. RBF kernel fonksiyonu doğruluğu önemli derecede etkileyen iki parametreye sahiptir. Bunlar cost (C) ve gamma (γ)'dır.

4.5.2.1. Başarısızlıktan bir yıl önce (t-1) dönemi için DVM analiz sonuçları

İşletmelerin başarısız olduğu t döneminden 1 yıl önce (t-1) yılında başarısız işletmelerin tahmini için oluşturulan DVM modelinin sınıflandırma oranları Tablo 4.9'da gösterilmiştir. Tabloda görüldüğü üzere eğitim seti için rastgele ayrılan 81 işletmeden başarısız olan 41 işletmeden 31 işletme ve geriye kalan 40 başarılı işletmenin ise 30'u doğru sınıflandırılmıştır. Eğitim seti için toplam sınıflandırma doğruluğu %75,31 olarak bulunmuştur. Test seti için ayrılan 59 işletmenin durumu tabloda incelendiğinde başarısız 29 işletmenin 22'si doğru sınıflandırılırken, geriye kalan başarılı 30 işletmenin 21'i doğru sınıflandırılmıştır. Test setinin toplam sınıflandırma doğruluğu %72,88 olarak bulunmuştur. DVM modeline ait bilgiler de Tablo 4.9'da gösterilmiştir.

Tablo 4.9. (t-1) Dönemi İçin Oluşturulan DVM Modelinin Özellikleri ve Sınıflandırma Matrisi

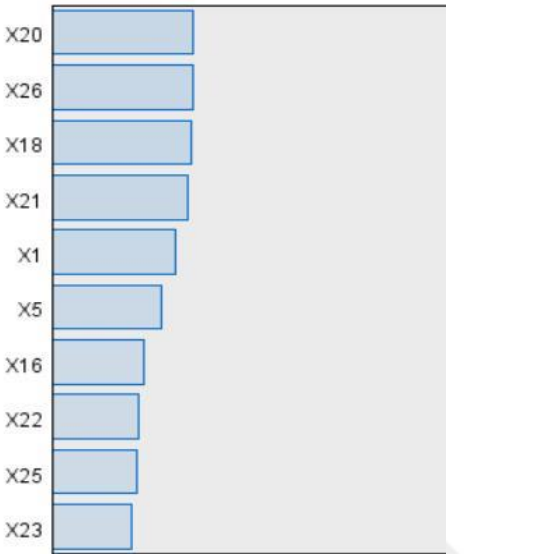
Düzenleme Parametresi (C)	10		
Epsilon	0.1		
Kernel Fonk.	(RBF) Radyal Tabanlı Fonksiyon		
Gamma γ	0.22		
DESTEK VEKTÖR MAKİNELERİ MODELİ EĞİTİM SETİ İÇİN SINIFLANDIRMA MATRİSİ (t-1 dönemi)			
		Gerçek Grup	
		Başarısız İşletmeler	Başarılı İşletmeler
Tahmin Edilen Grup	Başarısız İşletmeler	31	10
	Başarılı İşletmeler	10	30
	Toplam Sınıflandırma Doğruluğu = (31+30)/81 = % 75,31		
DESTEK VEKTÖR MAKİNELERİ MODELİ TEST SETİ İÇİN SINIFLANDIRMA MATRİSİ (t-1 dönemi)			
		Gerçek Grup	
		Başarısız İşletmeler	Başarılı İşletmeler
Tahmin Edilen Grup	Başarısız İşletmeler	22	7
	Başarılı İşletmeler	9	21
	Toplam Sınıflandırma Doğruluğu = (22+21)/59 = % 72,88		

Tablo 4.9'da belirtildiği üzere DVM çekirdek fonksiyonu olarak da radyal tabanlı fonksiyon seçilmiştir. Radyal tabanlı fonksiyonun parametrelerinden olan C=10 olarak belirlenirken gamma parametresi = 0,22 olarak modele tanıtılmıştır.

İşletmelerin başarısızlık durumunun tespiti için oluşturulan DVM modeline girdi olarak girilen değişkenler yukarıda YSA modelinde olduğu gibi işletmeleri sınıflandırmada farklı değerlerde etki göstermektedir. Tablo 4.10’da işletmelerin başarısızlığa uğradığı t yılından önceki yıl olan (t-1) yılında oluşturulan DVM modelindeki değişkenlerin, sınıflandırmada gösterdikleri etki değerleri gösterilmiştir.

Tablo 4.10. DVM Modeli için (t-1) Yılına Ait Önemli Değişkenler

	Değişken	Önem Değeri
1	X20	0,0692
2	X26	0,069
3	X18	0,0679
4	X21	0,0664
5	X1	0,0601
6	X5	0,0532
7	X16	0,0448
8	X22	0,0424
9	X25	0,0419
10	X23	0,0391



Tablo 4.10’da modelin oluşumunda önemli ilk 10 değişken gösterilmiştir. Tabloda da belirtildiği gibi ilk sırada X20 ile kodlanan ve modele girdi olan değişken “FVÖK/ Toplam Kaynaklara Oranı(Ekonomik Rantabilite)”dır. Daha sonra sırasıyla aralarında çok fazla değer farkı olmaksızın, X26,X18,X21,X1,X5,X16,X22,X25 ve X23 değişkenleridir. X20 oranı, vergi öncesi kar+ faiz giderleri / öz kaynaklar+ yabancı kaynaklar (pasif toplamı) bölünmesiyle elde edilir. Ekonomik Rantabilite şeklinde de adlandırılan bu oran, öz kaynaklar ve yabancı kaynaklar toplamının rantabilitesini ölçmek için kullanılır. Yönetimin, şirkete yatırılan fonların getirisini ölçmede kullandıkları çok önemli bir orandır. Aynı zamanda fonlardan yararlanma başarısının ölçümünde de kullanılır. Şirketlerin kullandıkları yabancı kaynakların getirisi faiz giderleridir. Bu sebeptendir ki vergi öncesi karın içinde indirim konusu olan faiz giderlerin kar tutarına eklenmesi gerekir. Bu oranın ikinci hesaplama yöntemi ise şu şekilde yapılır; yabancı kaynaklar toplamı yerine, yalnızca uzun vadeli yabancı kaynaklar + öz kaynaklar toplamı dikkate alınır. Bu hesap yönteminde

yatırımların finansmanında öz kaynak ile uzun vadeli yabancı kaynaklardan yararlanıldığı kabul edilir. Devamlı sermayenin getirisi ölçülür (Kazbek, 2015: 363). Sanayi şirketlerinin ekonomik rantabilitenin yüksek olması olumlu değerlendirilir.

4.5.2.2. Başarısızlıktan iki yıl önce (t-2) Dönemi İçin DVM Analiz Sonuçları

İşletmelerin başarısız olduğu t döneminden 2 yıl önce (t-2) yılında başarısız işletmelerin tahmini için oluşturulan DVM modelinin sınıflandırma oranları Tablo 4.11'de gösterilmiştir. Tabloda görüldüğü üzere eğitim seti için rastgele ayrılan 81 işletmeden başarısız olan 41 işletmeden 32 işletme ve geriye kalan 40 başarılı işletmenin ise 31'i doğru sınıflandırılmıştır. Eğitim seti için toplam sınıflandırma doğruluğu %77,78 olarak bulunmuştur. Test seti için ayrılan 59 işletmenin sınıflandırma durumu tabloda incelendiğinde başarısız 29 işletmenin 21'i doğru sınıflandırılırken, geriye kalan başarılı 30 işletmenin 21'i doğru sınıflandırılmıştır. Test setinin toplam sınıflandırma doğruluğu %71,19 olarak bulunmuştur. DVM modeline ait bilgiler de Tablo 4.11'de gösterilmiştir.

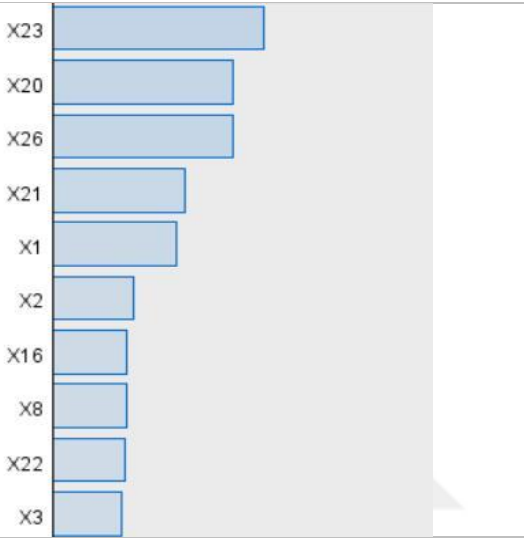
Tablo 4.11. (t-2) Dönemi İçin Oluşturulan DVM Modelinin Özellikleri ve Sınıflandırma Matrisi

Düzenleme Parametresi(C)	2		
Epsilon	0.1		
Kernel Fonk.	(RBF) Radyal Tabanlı Fonksiyon		
Gamma γ	0.12		
DESTEK VEKTÖR MAKİNELERİ MODELİ EĞİTİM SETİ İÇİN SINIFLANDIRMA MATRİSİ (t-2 dönemi)			
	Gerçek Grup		
	Başarısız İşletmeler	Başarılı İşletmeler	
Tahmin Edilen Grup	Başarısız İşletmeler	32	9
	Başarılı İşletmeler	9	31
	Toplam Sınıflandırma Doğruluğu = (32+31)/81 = % 77,78		
DESTEK VEKTÖR MAKİNELERİ MODELİ TEST SETİ İÇİN SINIFLANDIRMA MATRİSİ (t-2 dönemi)			
	Gerçek Grup		
	Başarısız İşletmeler	Başarılı İşletmeler	
Tahmin Edilen Grup	Başarısız İşletmeler	21	8
	Başarılı İşletmeler	9	21
	Toplam Sınıflandırma Doğruluğu = (21+21)/59 = % 71,19		

Tablo 4.11’de belirtildiği üzere DVM çekirdek fonksiyonu olarak da radyal tabanlı fonksiyon seçilmiştir. Radyal tabanlı fonksiyonun parametrelerinden olan $C=2$ ve $\epsilon=0,1$ olarak belirlenirken γ parametresi = 0,12 olarak modele tanıtılmıştır. Tablo 4.12’de işletmelerin başarısızlığa uğradığı t yılından önceki yıl olan (t-2) yılında oluşturulan DVM modelindeki değişkenlerin, sınıflandırmada gösterdikleri etki değerleri gösterilmiştir. Tabloda modelin oluşumunda önemli ilk 10 değişken gösterilmiştir.

Tablo 4.12. DVM Modeli için (t-2) Yılına Ait Önemli Değişkenler

	Değişken	Değeri
1	X23	0,1057
2	X20	0,0906
3	X26	0,090
4	X21	0,0661
5	X1	0,0625
6	X2	0,0409
7	X16	0,0372
8	X8	0,0371
9	X22	0,036
10	X3	0,0346



Tabloda da belirtildiği gibi ilk sırada X23 ile kodlanan ve modele girdi olan değişken “Brüt Kar Marjı”dır. Daha sonra sırasıyla aralarında çok fazla değer farkı olmaksızın, X20, X26, X21, X1, X2, X16, X8, X22 ve X3 değişkenleridir. X23 oranı, brüt kar veya zararın, net satışlara bölünmesi ile elde edilmiştir. Net satışlarla satış maliyeti arasındaki olumlu fark brüt satış karını oluşturmaktadır. Bu oran işletmenin faaliyet giderleri ile diğer giderlerini karşılayabilecek kadar kar elde edip etmediğini belirtmektedir. Bir şirketin belirli bir yıldaki brüt satış karı oranı, ilgili şirketin geçmiş yıllardaki brüt satış karı oranları ile sektördeki diğer şirketlerin oranları ile mukayese edilmesi ile değerlendirilir. İncelenen şirkette brüt satış karı oranının zaman içinde yükselme trendi göstermesi, şirketin lehine olan bir durumdur. Bir şirketin brüt satış karı oranının yükselmesi, aşağıda belirtilen nedenlerden kaynaklanabilir (Akgüç, 2011: 490):

- Maliyetler sabit kaldığı halde satış fiyatlarının yükselmesi,
- Satış fiyatları değişmediği halde maliyetlerin düşmesi,

- Satış fiyatlarının maliyetlerden daha hızlı artması,
- Maliyetlerdeki azalışın satış fiyatındaki düşüşten daha hızlı olması

4.5.2.3. Başarısızlıktan üç yıl önce (t-3) Dönemi İçin DVM Analiz Sonuçları

İşletmelerin başarısız olduğu t döneminden 3 yıl önce (t-3) yılında başarısız işletmelerin tahmini için oluşturulan DVM modelinin sınıflandırma oranları Tablo 4.13'de gösterilmiştir. Tabloda görüldüğü üzere eğitim seti için rastgele ayrılan 81 işletmeden başarısız olan 41 işletmeden 33 işletme ve geriye kalan 40 başarılı işletmenin ise 38'i doğru sınıflandırılmıştır. Eğitim seti için toplam sınıflandırma doğruluğu %87,65 olarak bulunmuştur. Test seti için ayrılan 59 işletmenin sınıflandırma durumu tabloda incelendiğinde başarısız 29 işletmenin 22'si doğru sınıflandırılırken, geriye kalan başarılı 30 işletmenin 20'si doğru sınıflandırılmıştır. Test setinin toplam sınıflandırma doğruluğu %71,19 olarak bulunmuştur. DVM modeline ait bilgiler ise Tablo 4.13'de gösterilmiştir.

Tablo 4.13. (t-3) Dönemi İçin Oluşturulan DVM Modelinin Özellikleri ve Sınıflandırma Matrisi

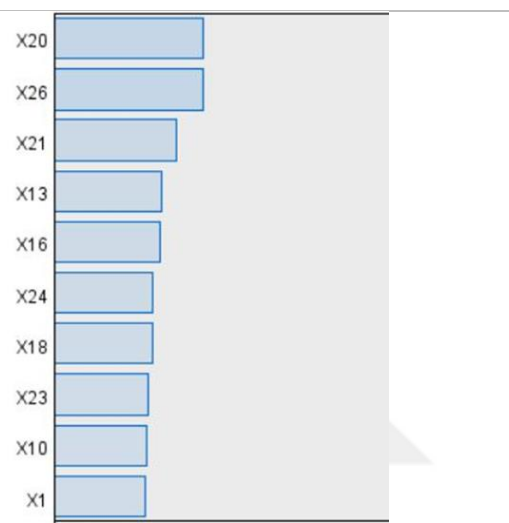
Düzenleme Parametresi(C)		10	
Epsilon		0.1	
Kernel Fonk.		(RBF) Radyal Tabanlı Fonksiyon	
Gamma γ		0.3	
DESTEK VEKTÖR MAKİNELERİ MODELİ EĞİTİM SETİ İÇİN SINIFLANDIRMA MATRİSİ (t-3 dönemi)			
		Gerçek Grup	
		Başarısız İşletmeler	Başarılı İşletmeler
Tahmin Edilen Grup	Başarısız İşletmeler	33	8
	Başarılı İşletmeler	2	38
	Toplam Sınıflandırma Doğruluğu = (33+38)/81 = % 87,65		
DESTEK VEKTÖR MAKİNELERİ MODELİ TEST SETİ İÇİN SINIFLANDIRMA MATRİSİ (t-3 dönemi)			
		Gerçek Grup	
		Başarısız İşletmeler	Başarılı İşletmeler
Tahmin Edilen Grup	Başarısız İşletmeler	22	7
	Başarılı İşletmeler	10	20
	Toplam Sınıflandırma Doğruluğu = (22+20)/59 = % 71,19		

Tablo 4.13'de belirtildiği üzere DVM çekirdek fonksiyonu olarak da radyal tabanlı fonksiyon seçilmiştir. Radyal tabanlı fonksiyonun parametrelerinden olan

C=10 ve epsilon= 0,1 olarak belirlenirken gamma parametresi = 0,3 olarak modele tanıtılmıştır. Tablo 4.14'de işletmelerin başarısızlığa uğradığı t yılından önceki yıl olan (t-3) yılında oluşturulan Destek Vektör Makineleri modelindeki değişkenlerin, sınıflandırmada gösterdikleri etki değerleri ve modelin oluşumunda önemli olan ilk 10 değişken gösterilmiştir.

Tablo 4.14. DVM Modeli için (t-3) Yılına Ait Önemli Değişkenler

	Değişken	Önem Değeri
1	X20	0,0858
2	X26	0,085
3	X21	0,0704
4	X13	0,0618
5	X16	0,061
6	X24	0,0568
7	X18	0,0562
8	X23	0,0539
9	X10	0,053
10	X1	0,0525



Tablo 4.14'de görüldüğü üzere (t-1) döneminde olduğu gibi ilk sırada X20 ile kodlanan değişken FVÖK /Toplam Kaynaklara Oranı (Ekonomik Rantabilite) dir. Ekonomik rantabilite daha önce anlatıldığı gibi bir şirketin kaynaklarını ne ölçüde karlı kullandığı hakkında bilgi verir. Şirket düşük faizli kredi kullanmışsa diğer koşullar aynı kalmak üzere, daha yüksek faizli kredi kullanan şirkete kıyasla daha karlı olacaktır. Gerçekte, daha az karlı gözükken şirket, kaynaklarını daha verimli kullanmış olabilir. Özellikle ulusal bazda ekonomi yönünden bir şirketin karlılığı değerlendirilirken, bu oranın, net kar/ öz sermaye şeklinde kullanılması daha doğru olacaktır (Akgüç, 2011: 485).

4.5.3. Ensemble (Topluluk) öğrenme tekniği ile oluşturulan modelin değerlendirilmesi

Bu bölümde makine öğrenmesi tekniklerinden olan ensemble (topluluk) öğrenme tekniği kullanılmıştır. Ensemble genel olarak bir araya getirme toplama anlamında kullanılır. Benzer ya da farklı algoritmaların bir araya getirilmesi şeklinde açıklanabilir. Algoritmalar iki ya da daha fazla olabilmektedir. Bu modeli oluşturmadaki amaç en iyi öğrenen algoritmanın sistemin gücünü artırması şeklindedir. Algoritmaların fonksiyon ve çalışma prensipleri farklı olduğundan her birinin yaklaşımı farklı olacaktır. Dolayısıyla her biri ayrı tahminde bulunacaklardır. Nihai karar verilirken bu algoritmaların tahminleri dikkate alınır. Bu nihai karar daha sağlam olacaktır. Bu çalışmada kullanılan yapay sinir ağları ve destek vektör makineleri beraber çalıştırılmış ve ensemble model elde edilmiştir. Ensemble model (t-1), (t-2), (t-3) yılları için oluşturulmuştur.

Ensemble öğrenme tekniğinde çeşitli algoritmalar kullanılmaktadır. Literatürde, De Bock vd. (2010) çalışmalarında Bagging, Virág ve Nyitrai (2014) çalışmalarında Adaboost ve Bagging, Ekinci ve Erdal (2017) çalışmalarında bagging ve boosting algoritmalarını kullanmışlardır. Bu çalışmada ise ensemble öğrenme modeli için daha önce açıklanan Boosting algoritması kullanılmıştır.

4.5.3.1. Başarısızlıktan bir yıl önce (t-1) dönemi için ensemble öğrenme analiz sonuçları

İşletmelerin başarısız olduğu t döneminden 1 yıl önce (t-1) yılında başarısız işletmelerin tahmini için oluşturulan ensemble sınıflandırma oranları Tablo 4.15’de gösterilmiştir.

Tablo 4.15. (t-1) Dönemi İçin Oluşturulan Ensemble Modelinin Özellikleri ve Sınıflandırma Matrisi

Ensemble Model İçin Kullanılan YSA Parametreleri		Ensemble Model İçin Kullanılan DVM Parametreleri	
Yapay Sinir Ağı Modeli	Çok Katmanlı	Düzenleme Parametresi(C)	10
Gizli Katman Sayısı	2	Epsilon	0,1
1.Katmandaki Nöron Sayısı	22	Kernel Fonk.	Radyal Tabanlı Fonksiyon
2.Katmandaki Nöron Sayısı	10	Gamma	0,22
Aktivasyon Fonksiyonu	Hiperbolik Tanjant		
ENSEMBLE ÖĞRENME MODELİ EĞİTİM SETİ İÇİN SINIFLANDIRMA MATRİSİ (t-			

1 dönemi)			
		Gerçek Grup	
		Başarısız İşletmeler	Başarılı İşletmeler
Tahmin Edilen Grup	Başarısız İşletmeler	32	9
	Başarılı İşletmeler	11	29
	Toplam Sınıflandırma Doğruluğu = (32+29)/81 = % 75,31		
ENSEMBLE ÖĞRENME MODELİ TEST SETİ İÇİN SINIFLANDIRMA MATRİSİ (t-1 dönemi)			
		Gerçek Grup	
		Başarısız İşletmeler	Başarılı İşletmeler
Tahmin Edilen Grup	Başarısız İşletmeler	23	6
	Başarılı İşletmeler	6	24
	Toplam Sınıflandırma Doğruluğu = (23+24)/59 = % 79,66		

Tablo 4.15’de görüldüğü üzere eğitim seti için rastgele ayrılan 81 işletmeden başarısız olan 41 işletmeden 32 işletme ve geriye kalan 40 başarılı işletmenin ise 29’u doğru sınıflandırılmıştır. Eğitim seti için toplam sınıflandırma doğruluğu %75,31 olarak bulunmuştur. Test seti için ayrılan 59 işletmenin sınıflandırma durumu tabloda incelendiğinde başarısız 29 işletmenin 23’ü doğru sınıflandırılırken, geriye kalan başarılı 30 işletmenin 24’ü doğru sınıflandırılmıştır. Test setinin toplam sınıflandırma doğruluğu %79,66 olarak bulunmuştur. Tablo 4.15’de belirtildiği üzere ensemble model oluşturulurken seçilen iki makine öğrenmesi modelinden biri olan DVM’nin çekirdek fonksiyonu olarak da radyal tabanlı fonksiyon seçilmiştir. Radyal tabanlı fonksiyonun parametrelerinden olan $C=10$ ve $\epsilon=0,1$ olarak belirlenirken γ parametresi = 0,22 olarak modele tanıtılmıştır. Ensemble model dahil edilen diğer makine öğrenmesi modeli olan MLP (multilayer perceptron) yani çok katmanlı algılayıcı YSA’nın parametreleri Tablo 4.15’de görüldüğü üzere 2 gizli katmandan oluşturulmuş ve 1. gizli katmanda 22 nöron bulunurken 2. gizli katmanda 10 nöron bulunmaktadır.

4.5.3.2. Başarısızlıktan iki yıl önce (t-2) dönemi için ensemble öğrenme analiz sonuçları

İşletmelerin başarısız olduğu t döneminden 2 yıl önce (t-2) yılında başarısız işletmelerin tahmini için oluşturulan ensemble sınıflandırma oranları Tablo 4.16’da gösterilmiştir. Tabloda görüldüğü üzere eğitim seti için rastgele ayrılan 81 işletmeden başarısız olan 41 işletmeden 37 işletme ve geriye kalan 40 başarılı işletmenin ise 35’ini doğru sınıflandırılmıştır. Eğitim seti için toplam sınıflandırma

doğruluğu %88 olarak bulunmuştur. Eğitim setinin bu yüksek sınıflandırma oranı ihtiyatlı karşılanmalı ve değerlendirme test seti üzerinden yapılmalıdır. Test seti için ayrılan 59 işletmenin sınıflandırma durumu tabloda incelendiğinde başarısız 29 işletmenin 23'ü doğru sınıflandırılırken, geriye kalan başarılı 30 işletmenin 23'ü doğru sınıflandırılmıştır. Test setinin toplam sınıflandırma doğruluğu %77,97 olarak bulunmuştur.

Tablo 4.16. (t-2) Dönemi İçin Oluşturulan Ensemble Modelinin Özellikleri ve Sınıflandırma Matrisi

Ensemble Model İçin Kullanılan YSA Parametreleri		Ensemble Model İçin Kullanılan DVM Parametreleri	
Yapay Sinir Ağı Modeli	Çok Katmanlı	Düzenleme Parametresi(C)	2
Gizli Katman Sayısı	2	Epsilon	0,1
1.Katmandaki Nöron Sayısı	14	Kernel Fonk.	Radyal Tabanlı Fonksiyon
2.Katmandaki Nöron Sayısı	12	Gamma	0,12
Aktivasyon Fonksiyonu	Hiperbolik Tanjant		
ENSEMBLE ÖĞRENME MODELİ EĞİTİM SETİ İÇİN SINIFLANDIRMA MATRİSİ (t-2 dönemi)			
		Gerçek Grup	
		Başarısız İşletmeler	Başarılı İşletmeler
Tahmin Edilen Grup	Başarısız İşletmeler	37	4
	Başarılı İşletmeler	5	35
	Toplam Sınıflandırma Doğruluğu = (37+35)/81 = % 88		
ENSEMBLE ÖĞRENME MODELİ TEST SETİ İÇİN SINIFLANDIRMA MATRİSİ (t-2 dönemi)			
		Gerçek Grup	
		Başarısız İşletmeler	Başarılı İşletmeler
Tahmin Edilen Grup	Başarısız İşletmeler	23	6
	Başarılı İşletmeler	7	23
	Toplam Sınıflandırma Doğruluğu = (23+21)/59 = % 77,97		

Tablo 4.16'da ensemble model oluşturulurken seçilen iki makine öğrenmesi modeli olan; YSA ve DVM'nin parametreleri gösterilmiştir. DVM'nin çekirdek fonksiyonu olarak da radyal tabanlı fonksiyon seçilmiştir. Radyal tabanlı fonksiyonun parametrelerinden olan C=2 ve epsilon= 0,1 olarak belirlenirken gamma

parametresi = 0,12 olarak modele tanıtılmıştır. YSA ise (t-1) döneminde olduğu gibi 2 gizli katmandan oluşmuş ve 1. gizli katmanında 14 nöron bulunurken 2. gizli katmanında 12 nöron bulunmaktadır.

4.5.3.3. Başarısızlıktan üç yıl önce (t-3) dönemi için ensemble öğrenme analiz sonuçları

İşletmelerin başarısız olduğu t döneminden 3 yıl önce (t-3) yılında başarısız işletmelerin tahmini için oluşturulan ensemble sınıflandırma oranları Tablo 4.17'de gösterilmiştir.

Tablo 4.17. (t-3) Dönemi İçin Oluşturulan Ensemble Modelinin Özellikleri ve Sınıflandırma Matrisi

Ensemble Model İçin Kullanılan YSA Parametreleri		Ensemble Model İçin Kullanılan DVM Parametreleri	
Yapay Sinir Ağı Modeli	Çok Katmanlı	Düzenleme Parametresi(C)	10
Gizli Katman Sayısı	2	Epsilon	0,1
1.Katmandaki Nöron Sayısı	17	Kernel Type	Radyal Tabanlı Fonksiyon
2.Katmandaki Nöron Sayısı	12	Gamma	0,3
Aktivasyon Fonksiyonu	Hiperbolik Tanjant		
ENSEMBLE ÖĞRENME MODELİ EĞİTİM SETİ İÇİN SINIFLANDIRMA MATRİSİ (t-3 dönemi)			
		Gerçek Grup	
		Başarısız İşletmeler	Başarılı İşletmeler
Tahmin Edilen Grup	Başarısız İşletmeler	33	8
	Başarılı İşletmeler	6	34
	Toplam Sınıflandırma Doğruluğu = (32+37)/81 = % 82,72		
ENSEMBLE ÖĞRENME MODELİ TEST SETİ İÇİN SINIFLANDIRMA MATRİSİ (t-3 dönemi)			
		Gerçek Grup	
		Başarısız İşletmeler	Başarılı İşletmeler
Tahmin Edilen Grup	Başarısız İşletmeler	24	5
	Başarılı İşletmeler	9	21
	Toplam Sınıflandırma Doğruluğu = (24+21)/59 = % 76,27		

Eğitim seti için rastgele ayrılan 81 işletmeden başarısız olan 41 işletmeden 33 işletme ve geriye kalan 40 başarılı işletmenin ise 34'ü doğru sınıflandırılmıştır. Eğitim seti için toplam sınıflandırma doğruluğu %82,72 olarak bulunmuştur. Tablo 4.17'de Test setinin performansı incelendiğinde, toplam 59 işletmeden başarısız 29

işletmenin 24'ü doğru sınıflandırılırken, geriye kalan başarılı 30 işletmenin 21'i doğru sınıflandırılmıştır. Test setinin toplam sınıflandırma doğruluğu %76,27 olarak bulunmuştur. Tablo 4.17'de oluşturulan modelin parametreleri incelendiğinde, DVM'nin çekirdek fonksiyonu radyal tabanlı fonksiyon seçilmiştir. Radyal tabanlı fonksiyonun parametrelerinden olan $C=10$ ve $\epsilon=0,1$ olarak belirlenirken γ parametresi = 0,3 olarak modele tanıtılmıştır. YSA ise (t-2) döneminde olduğu gibi 2 gizli katmandan oluşmuş ve 1. gizli katmanında 17 nöron bulunurken 2. gizli katmanında 12 nöron bulunmaktadır.

4.5.4. Tüm dönemler için modellerin performanslarının toplu gösterimi

Tablo 4.19'da analize dahil edilen işletmelerin başarısız olduğu ilk yılın 1, 2 ve 3 yıl öncesindeki durumlarını tahmin etmek için oluşturulan üç modelin eğitim seti ve test setinin duyarlılık, özgüllük ve doğruluk oranları gösterilmiştir.

Oluşturulan modellerin denetimi altın standart sonucuna göre yapılır. Bir modelin testinin değerlendirilmesi, aşağıdaki Tablo 4.18 (2x2) tipi çerçevesinde; üstte gerçek sonuç, yanda ise tahmin testi verilen bir sınıflandırma matrisi ile yapılır (Dirican, 2001: 26).

Tablo 4.18. Sınıflandırma Matrisi

		Gerçek Sonuç		
		Başarısız	Başarılı	TOPLAM
Tahmin Sonucu	Başarısız	A (GP)	B (YP)	A+B
	Başarılı	C(YN)	D (GN)	C+D
	Toplam	A+C	B+D	A+B+C+D

Gerçekte başarısız olan işletmeler tarafından; "A" gözü gerçekte de başarısız olup modelimizin de başarısız olarak sınıfladığı işletmeler, yani gerçek pozitifler (GP) olarak adlandırılır. Buna karşılık "C" gözündeki olgular, gerçekte başarısız olup, modelimizin hatalı olarak başarılı dediği yani yanlış negatif (YN) olgulardır. Bu çerçevede testin geneli için;

- DUYARLILIK (Sensitivity): Modelin, gerçek başarısız işletmeler içinden başarısızları ayırma yeteneğidir. $DUYARLILIK = A / (A+C) = GP / (GP + YN)$

Gerçekte başarılı olan işletmeler açısından, “D” gözü; gerçekte de başarılı olan işletmelerin tahmin sonucuna uygun olarak testinde başarılı olarak sınıflandırdığı gerçek negatif (GN) olgulardır. ”B” gözü ise gerçekte başarılı oldukları halde testin hatalı olarak başarısız dediği yanlış pozitif (YP) olgulardır.

- ÖZGÜLLÜK (Specificity) testin, gerçekte başarılılar içinden başarılıları ayırma yeteneğidir. $ÖZGÜLLÜK = D / (D + B) = GN / (GN + YP)$

Doğruluk oranı diğer adıyla doğru sınıflandırma oranı, oluşturulan modellerde doğru olarak tahmin edilen işletmelerin (başarısız ve başarılı) yüzdesini veren ve literatürde en yaygın olarak kullanılan performans ölçüsüdür (Torun 2007, s. 97). Literatürde performans ölçümü için doğruluk oranı daha sık kullanıldığından bu çalışmada da tahmin modellerinin performansı doğruluk oranıyla karşılaştırılmıştır. Tablo 4.19’da YSA ve DVM modellerinin eğitim ve test setinin (t-1), (t-2) ve (t-3) yıllarında en yüksek doğruluk oranına sahip sonuçları altı çizilerek gösterilmiştir. Başarısızlıktan bir yıl önce (t-1) yılında eğitim seti üzerinde YSA’nın performans yüzdeliğinin (%76,54) en yüksek olduğu görünmektedir. (t-1) yılı için test seti performansı değerlendirildiğinde, YSA (%79,66) ve ensemble (%79,66) oranları ile DVM’ye göre daha iyi bir doğruluk performansı göstermiştir. Başarısızlıktan iki yıl önceki (t-2) tahmin modellemelerinin performansı değerlendirildiğinde, eğitim seti (%88,89), test seti (%77,97) yüzdelikleri ile ensemble modeli YSA ve DVM modellerine göre daha iyi bir performans göstermiştir.

Eğitim setlerindeki yüksek yüzdelik ihtiyatlı karşılanmalı ve test seti üzerinden değerlendirme yapılması daha uygun olmaktadır. Çünkü eğitim verilerindeki hata istenen düzeye gelinceye kadar eğitim sürmektedir. Bu sebeple, modelin eğitiminde kullanılmayan test verileri üzerindeki performans da dikkate alınarak değerlendirme yapılmalıdır (Torun 2007: 100). Başarısızlıktan üç yıl önce (t-3) yılı için değerlendirildiğinde, eğitim setinde YSA ve DVM %87,65 oranıyla aynı performansı göstermiştir. Aynı yıl için test seti değerlendirildiğinde ise

ensemble model (%76,27), DVM ve YSA'ya göre daha yüksek bir doğruluk yüzdeliğine yani performansa sahiptir. Tüm yıllar ve tüm modeller için test seti üzerinden genel bir değerlendirilme yapıldığında, ensemble öğrenme modeli başarısızlıktan 1 yıl öncesi için YSA ile en yüksek aynı doğruluk yüzdeliğini elde ederken, 2 ve 3 yıl öncesinden ise doğru sınıflandırma yüzdesi en yüksek model olmuştur. Literatürde, Torun (2007), Aksoy (2018) ve Yakut (2012)'un çalışmalarında olduğu gibi başarısız yıldan geriye doğru gidildiğinde tahmin yüzdeliğinde azalma olduğu görülmektedir. Bu çalışmada 3 yıl geriye doğru gidildiğinde her ne kadar bir azalma olsa da doğruluk oranlarında büyük bir düşüş yaşanmamıştır. Yani başarısızlıktan 3 yıl önce de işletmelerin başarısızlık durumlarını tahmin etme performansı etkilidir.

Tablo 4.19. Oluşturulan Modellerin Duyarlılık, Özgüllük, Doğruluk Oranlarının Toplu Gösterimi

Dönem	YAPAY SİNİR AĞLARI			DESTEK VEKTÖR MAK.			ENSEMBLE		
	Duyarlılık	Özgüllük	Doğruluk	Duyarlılık	Özgüllük	Doğruluk	Duyarlılık	Özgüllük	Doğruluk
EGİTİM SETİ									
t-1	% 75	% 78,3	% 76,54	% 75,6	% 75	% 75,31	% 74,4	% 76,3	%75,31
t-2	% 91	% 84	% 87,65	% 78	% 77	% 77,78	% 88	% 89	% 88,89
t-3	% 86	% 89,4	% 87,65	% 94,2	% 82,6	% 87,65	% 84,6	% 80,9	% 82,72
TEST SETİ									
t-1	% 77,4	% 82,1	% 79,66	% 70,9	% 75	% 72,88	% 79,3	% 80	% 79,66
t-2	% 74,1	% 78,5	% 76,27	% 70	% 72,4	% 71,19	% 76	% 79	% 77,97
t-3	% 75	% 74,1	% 74,58	% 68,7	% 74	% 71,19	% 72,7	% 80,7	% 76,27

4.5.5. ROC (Receiver Operating Characteristic Curves) eğrileri ile oluşturulan modellerinin performanslarının değerlendirmesi

Bu bölümde, oluşturulan tahmin modellerinin ROC eğrisi altına kalan alanlarının hesabı yapılarak performans karşılaştırılması yapılacaktır.

4.5.5.1. ROC eğrileri (Receiver Operating Characteristic Curves)

ROC (Receiver Operating Characteristic Curves) eğrisinin ilk defa 2. Dünya Savaşı sırasında “radar sinyalleri”nin analizi için kullanılmıştır. Savaş sırasında


düşman uçaklarını, radar sinyallerini kullanarak saptamak amacıyla araştırmalara başlanmıştır. ROC eğrileri sonuç değişkeninin özellikle iki olasılıklı (başarı var-başarı yok, hastalık var-hastalık yok, vb.) olduğu, buna karşılık karar vermede kullanılacak değişkenin sürekli olduğu durumlarda kullanılırlar. ROC eğrileri bu sürekli değişken için olası tüm kesim noktalarını gösterir ve her kesim noktasında değişik sonuçların doğru pozitif, doğru negatif, yanlış pozitif ve yanlış negatif sıklığı hakkında kestirimler yapılmasına olanak sağlarlar. Verilen bir model için en iyi kesim noktasının saptanmasında, doğru ve yanlış kararların yararlarının hesaplanmasında kullanılırlar (Kılıç, 2013: 135).

Grafikler kullanılarak da modelin performansı değerlendirilebilir. Bu grafiksel ölçümlerden biri ROC analizidir. ROC eğrisi altında kalan alanın ölçülmesi ile yapılan ölçüm işletmenin performansı hakkında bilgi vermektedir. Sınıflandırmanın doğruluğu ROC eğrisi altında kalan alanın büyüklüğü ile ilişkilidir. Eğri altında kalan alan ne kadar büyükse, yapılan sınıflandırmanın doğruluğu o kadar yüksektir. Fakat eğrinin altında kalan bölgenin hesaplanması ile ilgili metotların bilinmesi gerekmektedir. Eğer yapılan sınıflandırma kötü ise, yani ROC eğrisi altındaki alanın beklenen değeri 0,80 ise veya değişkenlere ilişkin dağılımdan en az birinin güçlü bir şekilde iki modlu olduğundan şüphelenilmiyorsa ampirik metot veya binormal metot kullanılabilir (Keçeoğlu vd., 2016: 557). Provost vd. (1998) ve Langley (2000) sınıflandırma yöntemlerinin performansının ölçülmesinde ve karşılaştırılmasında etkili bir yöntem olan ROC eğrisi altında kalan alanların (Area Under the Curve=AUC) kullanılmasının önemli olduğunu belirtmişlerdir.

ROC eğrisi yöntemi aşağıda belirtilen hususlar dahilinde kullanılabilir (Dirican, 2001: 28):

- Oluşturulan modelin sınıflandırma gücünün belirlenmesine,
- Çeşitli Modellerin performanslarının kıyaslanmasına,
- Uygun pozitiflik eşiğinin belirlenmesine,
- Oluşturulan modellerin sonuçlarının kalitesinin takibinde,
- Uygulayıcının gelişiminin izlenmesine ve
- Farklı uygulayıcıların etkinliklerinin kıyaslanmasına olanak sağlar.

ROC (Receiver Operating Characteristic Curves) eğrisi ile elde edilecek koordinat sisteminin ordinatında oluşturulan model testinin gerçek pozitif değeri (duyarlılık), apsisinde ise yanlış pozitif değeri (1-özgüllük) yer alır. Oluşturulan model ne kadar iyi ise eğri yukarıya (yüksek duyarlılık bölgesi) ve sola (düşük yanlış pozitif oranı bölgesi) doğru kayar. Şekil 4.1'de görüldüğü gibi, oluşturulan model eğer ideal bir değerde ise ROC eğrisi (0,0) –(0,1) –(1,1) noktalarını birleştirir. Buna karşın ROC çizimi $y=x$ fonksiyonuna yaklaştıkça test başarısız olacaktır. Çünkü bu modelde yanlış değerlerin oranı yükselmektedir. $y=x$ fonksiyonun altındaki ROC eğrisine sahip model başarısızdır. ROC eğrisi altında kalan alan 0,50 ile 1,00 arasında değerler almaktadır. Yukarıda belirtildiği gibi eğri altında kalan bölge ne kadar büyükse, modelin ayırım yeteneği o kadar etkilidir. Bu alan 0,975 ve daha üzerinde ise mükemmel sayılmaktadır (Dirican, 2001: 28-29).



Şekil 4.1. İdeal ve Kötü Performans Gösteren ROC Eğrileri (Dirican, 2001)


ROC (Receiver Operating Characteristic Curves) eğrilerinde; x ekseninde Yanlış Pozitif Orantı bulunurken, y ekseninde Doğru Pozitif Orantı yer almaktadır. Farklı eşik değerleri için Yanlış Pozitif Orantı ve Doğru Pozitif Orantı değerleri yani duyarlılık ve 1-seçicilik değerleri hesaplanır. ROC Eğrisi (0,0) ile (1,1) arasında artan bir fonksiyondur. ROC (Receiver Operating Characteristic Curves) analizi sonrası sınıflandırma başarısı değerlendirilen bir testin yararsız mı yoksa çok iyi bir test mi olduğu kararı verilebilir. Model, başarılı olan işletmeler ve başarısız olan işletmeleri birbirinden ayıramıyor ise o model yararsız bir modeldir ve para ile yazı-tura atmaktan farksız bir olasılığa (%50) sahiptir. Model, başarılı olanları ve başarısız olanları birbirinden tam anlamıyla sınıflayabilir ise o modele mükemmel bir model

denebilir. Bu durumda Doğru Pozitif Orantı (c)=1, Yanlış Pozitif Orantı (c)=0 şeklinde gösterilir. Literatürde oluşturulan modellerin birçoğu yararsız test ile mükemmel test arasında bir performansa sahiptir. ROC grafiğinin sol üst köşesine yaklaşıldıkça modelin ayırt etme gücü artar, mükemmelliğe yaklaşırlar. Modelin doğru karar vermede gücünü değerlendirmede kullanılan ölçütlerden biri de “ROC Eğrisi Altında Kalan Alan”dır. Eğri altında kalan alan (area under the curve=AUC) en büyük “1” değerini alabilir ve bu durum altın test/model şeklinde belirtilmektedir. Pratik olarak alabileceği en küçük değer ise “0,50” dir. Başarılı/Başarısız tamamen şansa bağlı olarak (örneğin para atışı ile) ayırt edilirse böyle bir durum ortaya çıkar (Kılıç, 2013: 136).

4.5.5.2. YSA modelinin ROC eğrisi yardımıyla performanslarının değerlendirilmesi

4.5.5.2.1. (t-1) dönemi için ROC eğrisi altında kalan alanın değerlendirilmesi

Finansal başarısızlık, başarısızlığın 1 yıl önceden (t-1) tahmini için geliştirilen YSA modelinin ROC eğrisi altında kalan alan (area under the curve=AUC) eğitim seti için 0,85 bulunurken test seti için 0,81 bulunmuştur (Tablo 4.20). En kötü performans ya da başka bir tanımla yararsız test/model olarak tanımlanan 0,5’den büyük bulunmuştur (Şekil 4.2). Bu durum modelin yani Yapay Sinir Ağının (t-1) dönemi için başarılı ve başarısız işletmeleri sınıflandırmada yararlı bir model olduğunu göstermektedir.




Şekil 4.2. (t-1) Dönemi YSA Modeli İçin ROC Eğrisi

Tablo 4.20. (t-1) Dönemi YSA Modeli İçin ROC Eğrisi Altında Kalan Alan

Yapay Sinir Ağları (t-1)	Eğitim	Test
Roc Eğrisi Altında Kalan Alan	0,85	0,81

4.5.5.2.2. (t-2) dönemi için ROC eğrisi altında kalan alanın değerlendirilmesi

Finansal başarısızlık, başarısızlığın 2 yıl önceden (t-2) tahmini için geliştirilen Yapay Sinir Ağı modelinin ROC eğrisi altında kalan alan (area under the curve=AUC) eğitim seti için 0,93 bulunurken test seti için 0,79 hesaplanmıştır (Tablo 4.21). Hesaplanan değer 0,5'den büyük bulunmuştur. Bu durum Yapay Sinir Ağının (t-2) dönemi için başarılı ve başarısız işletmeleri sınıflandırmada yararlı bir model olduğunu göstermektedir.




Şekil 4.3. (t-2) Dönemi YSA Modeli İçin ROC Eğrisi

Tablo 4.21. (t-2) Dönemi YSA Modeli İçin ROC Eğrisi Altında Kalan Alan

Yapay Sinir Ağları (t-2)	Eğitim	Test
Roc Eğrisi Altında Kalan Alan	0,93	0,79

4.5.5.2.3. (t-3) dönemi için ROC eğrisi altında kalan alanın değerlendirilmesi

Finansal başarısızlık, başarısızlığın 3 yıl önceden (t-3) tahmini için geliştirilen Yapay Sinir Ağı modelinin ROC eğrisi altında kalan alan (area under the curve=AUC) eğitim seti için 0,95 bulunurken test seti için 0,75 hesaplanmıştır (Tablo 4.22). Hesaplanan değer en kötü performans değeri olan 0,5'den büyük bulunmuştur. Bu durum modelin yani Yapay Sinir Ağı'nın (t-3) dönemi için başarılı ve başarısız işletmeleri sınıflandırmada yararlı bir model olduğunu göstermektedir.



Şekil 4.4. (t-3) Dönemi YSA Modeli İçin ROC Eğrisi

Tablo 4.22. (t-3) Dönemi YSA Modeli İçin ROC Eğrisi Altında Kalan Alan


Yapay Sinir Ağları (t-3)	Eğitim	Test
Roc Eğrisi Altında Kalan Alan	0,95	0,75

4.5.5.3. DVM modelinin ROC eğrisi yardımıyla performanslarının değerlendirilmesi

Yukarıda Yapay Sinir Ağı modeli için hesaplanan ROC eğrisi altında kalan alan (area under the curve=AUC) değerleri, Destek Vektör Makineleri modeli için de hesaplanmıştır. Tahmin modelinin (t-1),(t-2) ve (t-3) yılları için yararlı bir model olup olmadığı analiz edilmiştir.

4.5.5.3.1. (t-1) dönemi için ROC eğrisi altında kalan alanın değerlendirilmesi

Finansal başarısızlık, başarısızlığın 1 yıl önceden (t-3) tahmini için geliştirilen Destek Vektör Makineleri modelinin ROC eğrisi altında kalan alan (area under the curve=AUC) eğitim seti için 0,83 bulunurken test seti için 0,79 bulunmuştur (Tablo 4.23). Hesaplanan değer en kötü performans değeri olan 0,5'den büyük bulunmuştur. Grafikte de görüldüğü üzere eğri kuzey-batı yönüne yakın yani 0,5'den yukarıdadır. Bu durum DVM'nin (t-1) dönemi için başarılı ve başarısız işletmeleri sınıflandırmada yararlı bir model olduğunu göstermektedir.




Şekil 4.5. (t-1) Dönemi DVM Modeli İçin ROC Eğrisi

Tablo 4.23. (t-1) Dönemi DVM Modeli İçin ROC Eğrisi Altında Kalan Alan

DVM (t-1)	Eğitim	Test
Roc Eğrisi Altında Kalan Alan	0,83	0,79

4.5.5.3.2. (t-2) dönemi için ROC eğrisi altında kalan alanın değerlendirilmesi

Finansal başarısızlık, başarısızlığın 2 yıl önceden (t-2) tahmini için geliştirilen Destek Vektör Makineleri modelinin ROC eğrisi altında kalan alan (area under the curve=AUC) eğitim seti için 0,87 bulunurken test seti için 0,78 bulunmuştur (Tablo 4.24). Bu durum DVM'nin (t-2) dönemi için başarılı ve başarısız işletmeleri sınıflandırmada yararlı bir model olduğunu göstermektedir.




Şekil 4.6. (t-2) Dönemi DVM Modeli İçin ROC Eğrisi

Tablo 4.24. (t-2) Dönemi DVM Modeli İçin ROC Eğrisi Altında Kalan Alan

DVM (t-2)	Eğitim	Test
Roc Eğrisi Altında Kalan Alan	0,87	0,78

4.5.5.3.3. (t-3) dönemi için ROC eğrisi altında kalan alanın değerlendirilmesi



Şekil 4.7. (t-3) Dönemi DVM Modeli İçin ROC Eğrisi

Finansal başarısızlık, başarısızlığın 3 yıl önceden (t-3) tahmini için geliştirilen Destek Vektör Makineleri modelinin ROC eğrisi altında kalan alan (area under the curve=AUC) eğitim seti için 0,91 bulunurken test seti için 0,80 bulunmuştur (Tablo 4.25). Bu durum DVM'nin (t-3) dönemi için başarılı ve başarısız işletmeleri sınıflandırmada yararlı bir model olduğunu göstermektedir.

Tablo 4.25. (t-3) Dönemi DVM Modeli İçin ROC Eğrisi Altında Kalan Alan

DVM (t-3)	Eğitim	Test
-----------	--------	------


Roc Eğrisi Altında Kalan Alan	0,91	0,80
--------------------------------------	------	------

4.5.5.4. Ensemble modelin ROC eğrisi yardımıyla performanslarının değerlendirilmesi

Bu bölümde oluşturulan ensemble öğrenme modelinin ROC eğrisi yardımıyla değerlendirilmesi yapılmıştır.

4.5.5.4.1. (t-1) dönemi için ROC eğrisi altında kalan alanın değerlendirilmesi

Finansal başarısızlık, başarısızlığın 1 yıl önceden (t-1) tahmini için geliştirilen ensemble öğrenme modelinin ROC eğrisi altında kalan alan (area under the curve=AUC) eğitim seti için 0.86 bulunurken test seti için 0,82 bulunmuştur (Tablo 4.26). Hesaplanan değer en kötü performans değeri olan 0,5'den büyük bulunmuştur. Bu durum öğrenme modelin (t-1) dönemi için başarılı ve başarısız işletmeleri sınıflandırmada yararlı bir model olduğunu göstermektedir.



Şekil 4.8. (t-1) Dönemi Ensemble Modeli İçin ROC Eğrisi


Tablo 4.26. (t-1) Dönemi Ensemble Modeli İçin ROC Eğrisi Altında Kalan Alan

Ensemble (t-1)	Eğitim	Test
Roc Eğrisi Altında Kalan Alan	0,86	0,82

4.5.5.4.2. (t-2) dönemi için ROC eğrisi altında kalan alanın değerlendirilmesi

Finansal başarısızlık, başarısızlığın 2 yıl önceden (t-2) tahmini için geliştirilen ensemble öğrenme modelinin ROC eğrisi altında kalan alan (area under the curve=AUC) eğitim seti için 0,96 bulunurken test seti için 0,80 bulunmuştur (Tablo 4.27). Hesaplanan değer en kötü performans değeri olan 0,5'den büyük

bulunmuştur. Bu durum öğrenme modelin (t-1) dönemi için başarılı ve başarısız işletmeleri sınıflandırmada yararlı bir model olduğunu göstermektedir.




Şekil 4.9. (t-2) Dönemi Ensemble Modeli İçin ROC Eğrisi

Tablo 4.27. (t-2) Dönemi Ensemble Modeli İçin ROC Eğrisi Altında Kalan Alan

Ensemble (t-2)	Eğitim	Test
Roc Eğrisi Altında Kalan Alan	0,96	0,80

4.5.5.4.3. (t-3) dönemi için ROC eğrisi altında kalan alanın değerlendirilmesi

Finansal başarısızlık, başarısızlığın 3 yıl önceden (t-3) tahmini için geliştirilen ensemble öğrenme modelinin ROC eğrisi altında kalan alan (area under the curve=AUC) eğitim seti için 0,93 bulunurken test seti için 0,77 bulunmuştur (Tablo 4.28). Hesaplanan değer en kötü performans değeri olan 0,5'den büyük bulunmuştur. Bu durum öğrenme modelin (t-3) dönemi için başarılı ve başarısız işletmeleri sınıflandırmada yararlı bir model olduğunu göstermektedir.



Şekil 4.10. (t-3) Dönemi Ensemble Modeli İçin ROC Eğrisi

Tablo 4.28. (t-3) Dönemi Ensemble Modeli İçin ROC Eğrisi Altında Kalan Alan

Ensemble (t-3)	Eğitim	Test
Roc Eğrisi Altında Kalan Alan	0,93	0,77

4.5.5.5. Tüm dönemler için oluşturulan modellerin performanslarının ROC eğrisi yardımıyla toplu olarak gösterimi

Tablo 4.29. Tüm Modellerin ROC Eğrisinin Altında Kalan Alanların Gösterimi

	DÖNEM	YSA	SVM	Ensemble
EĞİTİM	t-1	0,85	0,83	0,86
	t-2	0,93	0,87	0,95
	t-3	0,95	0,91	0,93
TEST	t-1	0,81	0,79	0,82
	t-2	0,79	0,78	0,74
	t-3	0,75	0,80	0,77

Tablo 4.29'da finansal başarısızlığın tahmini için geliştirilen iki modelin ROC eğrisi altında kalan alanların (area under the curve=AUC) hesaplanması sonucu ortaya çıkan sonuçlar toplu halde gösterilmiştir. Tabloda eğitim ve test setlerinde (t-1),(t-2) ve (t-3) yıllarında AUC değeri en yüksek olan sonuç altı çizili halde gösterilmiştir. Tablo 4.28'de görüldüğü üzere (t-1), (t-2) yıllarında eğitim setleri için AUC 0,86, 0,95 değerleri ile ensemble öğrenme modeli daha iyi performans göstermiştir. (t-3) yılında ise Yapay Sinir Ağı modeli AUC= 0,95 oranı ile diğer modellere göre daha iyi performans göstermiştir. Test seti için değerlendirme yapılırsa, ensemble öğrenme modeli (t-1) yılında 0,86, Yapay Sinir Ağı modeli (t-2) yılında 0,79 ve Destek Vektör Makineleri (t-3) yılında 0,80 AUC değerleri ile en iyi

değerleri almıştır. Genel bir değerlendirme yapılırsa, YSA, DVM ve ensemble modelleri (t-1),(t-2) ve(t-3) yıllarının hepsinde eğitim ve test seti için 0,50'nin üzerinde AUC değerleri almıştır. Bu durum, oluşturulan modellerin kullanılmasının şansa dayalı tahmin yapmaktan daha iyi olması anlamına gelmektedir.

Literatürde benzer çalışmalarda, Odom ve Sharda (1990), başarısızlıktan bir yıl öncesi için yapılan tahmin çalışmasında YSA yöntemi ile iflas etmiş işletmeleri %81,48 oranında, iflas etmemiş işletmeleri ise %82,14 oranında doğru tahmin etmişlerdir.

Jo vd. (1997) yaptıkları çalışmada YSA kullanarak 1990-1992 yıllarını analiz etmişlerdir. Çalışma sonucunda YSA modelinin başarısızlıktan bir yıl öncesi için ortalama doğru sınıflandırma başarısını %83,79 olarak bulmuşlardır.

G. Zhang vd. (1999) yaptıkları çalışmada 220 firmanın başarısızlık durumunu analiz etmişlerdir. Elde ettikleri sonuçlara göre, YSA modelinin sınıflandırma başarısı %80,46 olarak bulunmuştur.

Atiya (2001) başarısız firmaların tespitinde YSA kullanmıştır. Çalışma sonucunda, 120 finansal oran kullanarak oluşturduğu modelin %81,46 oranında doğru tahminde bulunduğunu ortaya koymuştur.

Torun (2007) yaptığı çalışmada diskriminat, lojistik regresyon ve YSA ile model oluşturmuş ve YSA'da başarısızlıktan bir yıl önce yani (t-1) yılında test seti için %90, (t-2) yılında %86,7, (t-3) yılında %73,3, (t-4) yılında %70 ve son yıl olan (t-5) yılında ise %70 oranında bir sınıflandırma doğruluğu elde etmiştir.

Akkaya vd. (2009) çalışmalarında YSA'da test setinde (t-1) yılı için %81 oranında performans elde etmişlerdir.

Çelik (2009) yaptığı çalışmada başarısız firmaları tahmin etmek üzere üç model kullanmıştır. Bunlar; YSA, Diskriminant Analizi ve Altman'ın Z Modelleridir. (t-3) yılında %91,4 oranıyla zarar eden işletmeleri doğru sınıflandırmıştır. Çalışma sonucunda 3 yıl öncesine kadar geliştirdiği tahmin modellerinde YSA modeli tüm yıllarda en iyi performansı göstermiştir.

Bu çalışmada ise YSA'da (t-1) yılında %79,66, (t-2) yılında %76,27 ve (t-3) yılında ise %74,58 oranında bir doğruluk oranı elde edilmiştir. Literatürdeki diğer sonuçlar ile karşılaştırıldığında yaklaşık sonuçların elde edildiği görülmektedir.

Torun (2008) makroekonomik oranları da bağımsız değişkenlere ekleyip çıkararak iki model oluşturmuş, üç yıllık veriler ile destek vektör makinelerini ve yapay sinir ağlarını banka başarısızlığının tahmininde uygulamış ve DVM'nin (%83,78) YSA'ya (%86,49) göre daha iyi performans gösterdiğini açıklamıştır.

Yakut (2012) yaptığı çalışmada, YSA yönteminin destek vektör makineleri yöntemine göre daha iyi sonuçlar verdiğini gözlemlemiştir. Başarısızlıktan 3 yıl önceki (t-3) performansları; DVM (%76,7), YSA (82,5) oranlarında bulunmuştur.

Emir (2013) çalışmasında, makine öğrenmesi yöntemlerinden olan YSA ve DVM yöntemlerinin İstanbul Menkul Kıymetler Borsası Ulusal 100 Endeksi'nin yön tahmininde kullanılabilirliklerini araştırmıştır. Boyutu azaltılmış veri kümesi üzerinde DVM sınıflandırıcılarının performansı (%68,5) tüm değişkenlerin kullanıldığı veri kümesindeki performansa göre (%71,9) azalmıştır. YSA sınıflandırıcılarında ise tüm değişkenlerin kullanıldığı veri kümesindeki performans (%73,7) ile boyut azaltılmış veri kümesi üzerindeki performans (%73,5) birbirine çok yakındır. Tüm analizlerde YSA, DVM yöntemine göre daha iyi sonuçlar vermiştir.

Bu çalışmada ise (t-1) döneminde YSA (%79,66), DVM'ye (%72,88) göre daha iyi performans göstermiştir. Diğer (t-2), (t-3) dönemlerinde de YSA, DVM'ye göre daha iyi performans göstermiştir. Burada analize dahil edilen sektörlerin ve oranların farklı oluşu bu sonucu ortaya çıkarmaktadır. Yapılan analizin kapsadığı yılların farklı oluşu ve analizin kapsadığı yıllar içindeki krizler, tablo standartları gibi nedenler sonuçların da farklılaşmasını sağlayabilmektedir.

Ekinci ve Erdal (2017) bankaların başarısızlığını öngörme ve sınıflandırma çalışmalarında, ensemble öğrenme tekniğini kullanmışlardır. Çalışmalarında, normal öğrenme modeli, ensemble öğrenme modeli ve hibrit ensemble öğrenme modeli olarak üç model oluşturmuşlardır. Çalışma sonucunda ensemble ve hibrit ensemble modellerinin diğer modele göre daha iyi sınıflandırma performansı gösterdiği ortaya çıkmıştır. Ayrıca ensemble modellerinin doğruluk ve özgüllük yüzdeleri diğer

modelden yüksek çıkmıştır. Ekinci ve Erdal (2017) çalışmalarında ROC eğrilerini kullanarak oluşturdukları sınıflandırma modellerinin performansını ölçmüşler ve ensemble modellerinde eğri altında kalan alanın daha büyük olduğu sonucuna varmışlardır. Bu çalışmada da ensemble model, tek olarak oluşturulan YSA ve DVM modellerine göre daha iyi performans göstermiştir.



BEŞİNCİ BÖLÜM

SONUÇ VE ÖNERİLER

Globalleşen dünyada sınırlar birbirine daha yakınlaşmış ve bu durum işletmelerin faaliyet gösterdiği sektörlerde rekabet etmeyi zorlaştırmıştır. Artık finansal anlamda ülkelerin içinde buldukları sıkıntılı durumlar diğer ülkelere de bulaşabilmekte ve sonrasında global krizler ortaya çıkabilmektedir. İşletmelerin başarısızlığını sadece bir finansal olay olarak değerlendirmek doğru sonuçlara ulaşmaya engel olacaktır. İşletmelerin mali sıkıntı içine girip başarısızlığa sürüklenmeleri aynı zamanda ülkelerin sosyolojik, ekonomik, politik ve istihdam gibi yapılarına da zarar verecek önemli hadisedir. Bir işletmenin başarısız olması durumunda o işletme ile ilişki içindeki tüm paydaşlar zarar görecektir. Bu paydaşların zarar görmesi diğer işletmelere de bulaşabilecek ve bu halka giderek büyüyebilecektir. Bu bulaşma ve büyüme etkisi, işsizlik sorunu, istihdam sorunu ve ülke bazında ekonomik krizleri doğurabilecektir.

Yukarıda sayılan sebeplerden dolayı işletmelerin finansal başarısızlığının gerçekleşmeden önce tahmin edilmesi her zaman önemli olmuştur. İşletme, tahmin sonuçları doğrultusunda alınan kritik önlemler ile sıkıntılı duruma düşmekten kurtulabilmektedir. Bu finansal tahmin modellerinin geliştirilmesi, yönetilmesi ve uygulanması süresince işletmenin yönetim kademesine büyük görevler düşmektedir. Karar alıcı pozisyonundaki yöneticilerin yapacağı finansal stratejik eylem hareketleri hayati önem taşımaktadır. Karar alıcıların bu kararlarını doğru ve etkili vermesi için de etkili ve güçlü tahmin modellerinin uygulanması gerekmektedir.

Literatürde finansal başarısızlığın tahmininde geleneksel istatistiksel metotlar ile yapay zekâ ve makine öğrenmesi gibi yöntemler kullanılmaktadır. Bu çalışmada doğrusal olmayan ve karmaşık verileri işleyebilen yapay zekâ metotlarından olan yapay sinir ağları, destek vektör makineleri ve ensemble (topluluk) öğrenme modelleri kullanılmıştır. Sınıflandırma problemlerinde kullanılan

bu üç yöntem BİST imalat sanayi şirketleri üzerinde uygulanmış ve üç modelin performansı karşılaştırılmıştır.

Çalışmada oluşturulan modellerin kısıtları mevcuttur. Analizlerde yer alan işletmeler BİST ve KAP'ın kurumsal web sitelerinden elde edilmiştir. Bu işletmelerin bir kısmı halen işlem görmekte iken, bir kısmı da geçmişte BİST'te işlem görmüş fakat şu anda iflas, kottan çıkma, işlem sırası kapatılan, pazar değişikliği gibi nedenlerle işlem görmeyen işletmelerdir. Çalışmanın örneklemini oluşturan işletmeler 2008-2016 yıllarını kapsayan 8 yıllık bir dönem içinde BİST'te işlem görmüş/görmekte olan işletmelerdir. Veri setinin 8 yıllık bir dönemi kapsamasının nedeni, finansal başarısızlığa uğramış işletme sayısını artırma çabasıdır. Bu tip çalışmalarda model oluşturulurken başarısız işletmelerin sayısı fazla olmamakta, bu nedenle analizin yapıldığı yıl aralığının arttırılması gerekmektedir. Aksi takdirde az veri ve örneklem ile model oluşturmada zorluk yaşanabilmektedir.

Çalışmada finansal anlamda başarısız işletmelerin başarısızlığı, 1, 2 ve 3 yıl öncesinden tespit edilmeye çalışılmıştır. Ayrıca ROC analizi ile eğri altında kalan alan hesaplanarak modelin performansı test edilmiştir. Oluşturulan her üç tahmin modeli, 3 yıl öncesinden %70 üzeri bir doğruluk oranı ile iyi performans göstermiştir. Üç modelin yani YSA, DVM ve Ensemble tekniklerinin performansları karşılaştırıldığında Ensemble modelinin (t-2) ve (t-3) yıllarında YSA ve DVM'ye modellerine göre daha iyi performans gösterdiği gözlemlenmiştir. Literatürde başarısızlıktan geriye doğru tahmin gücünün azalmakta olduğu tespit edilmiştir. Bu çalışmada da ilk başarısızlık yılından geriye doğru doğruluk oranında bir azalma olmasına rağmen aradaki fark fazla değildir. Bu durum çalışmada oluşturulan modellerin başarısız işletmelerin 3 yıl öncesinden %70 üzeri bir doğruluk oranıyla tespit edilebileceğini göstermiştir.

Çalışmada ROC eğrisi altında kalan alanlar hesaplanarak, modellerin performansları karşılaştırıldığında, her üç modelin tüm yıllarda 0,5 üzerinde bir değer aldıkları görülmektedir. Bu değer, oluşturulan modellerin yararlı olduğunu ve kullanılan değişkenlerin işletmelerin başarılı-başarısız şeklinde sınıflandırılmasında etkili olduğunu ifade etmektedir. ROC eğrisi altında kalan 0,5 üzeri bir alan, işletmelerin başarısız-başarılı olarak sınıflandırılmasının şansa bırakılması yerine bu modellerin kullanılarak önceden tahmin edilebileceği sonucunu ortaya koymaktadır.

Çalışmada şirketlerin başarısızlık durumlarının öngörüsü için finansal oranlardan yararlanılmıştır. Bu finansal oranlar oluşturulan modellerde değişkenleri teşkil etmektedir. YSA ve DVM makine öğrenmesi modelleri bu 26 değişkenin değerleri ile öğrenmekte ve sonrasında test ederek sonuç çıkarmaktadır. Uygulama bölümünde görüldüğü üzere oranların önem değerleri arasında çok fark olmasa da modeller bazı değişkenlere daha fazla ağırlık vererek, başarı ya da başarısızlık sonucunu çıktılar olarak üretmişlerdir. YSA modelimizde (t-1) ve (t-3) döneminde X21 değişkeni tahminde önemli değişkenler arasında ilk sırada olurken (t-2) döneminde ikinci önemli değişken pozisyonundadır. X21 değişkeni yani toplam varlıkların karlılığı oranı işletmelerin varlıklarını ne ölçüde karlı kullandığının tespiti için önemli bir orandır. Özellikle sermaye yoğun imalat sanayi şirketlerinin duran varlıkları bilançoda önemli bir yer almaktadır. Bu varlıkların verimli kullanılması, çıktı olarak üretime ve satışa dönüşmesi ile ortakların elde edeceği kar miktarı da artacaktır. Sanayi şirketleri, kaynakları (öz kaynak, borç) ile elde ettiği bu varlıklarını kara dönüştüremediği takdirde finansal sıkıntı içine girebilir ve dolaylı ve dolaysız maliyetler ile karşılaşabilir.

DVM makine öğrenmesi modelimiz ise başarılı ve başarısız şirketleri tahmin ederken, bazı oranların sayısal verilerine daha fazla ağırlık vererek çıktılar üretmiştir. (t-1) ve (t-3) dönemlerinde X20 oranına daha fazla ağırlık verilmiş, (t-2) döneminde ise X23 oranı ilk sırada önemli değişken olurken, X20 oranı ikinci önemli tahmin değişkeni olmuştur. X20 oranı FVÖK / Toplam kaynaklara oranını ifade eden bir oran olurken aynı zamanda “ekonomik rantabilite” şeklinde de adlandırılmaktadır. Özellikle imalat sanayi şirketlerinin ekonomik rantabilitesinin yüksek olması önemlidir. İmalat sanayileri üretim faaliyetlerinin devamı ve sektörde büyüebilmek için yabancı kaynak (kısa yada uzun vadeli) veya öz sermaye kullanırlar. Devamlı sermaye getirisi olan bu ölçüm, üretim faaliyetleri yapan imalat sanayi şirketleri için önemlidir. Tahmin modelinin de bu oranı önemli görüp ağırlık vermesi başarılı/başarısız şirketlerin ayırımında önemlidir. Analizde kullanılan oranlar yorumlanırken, imalat sanayisi şirketinin bulunduğu sektöre, rakip işletmelerin durumlarına ve işletmenin önceki yıllardaki verilerine göre değerlendirme yapılmalıdır. Analizde kullanılan tüm oranlar işletmelerin başarısızlık tahmininde etkilidir. Oranların değerlendirilmesi ve oluşturulan modellerin çıktısı ile yatırımcı, yönetici, denetleme kuruluşları, devlet ve kredi veren kuruluşlar ilgili

işletmenin gelecekteki durumu hakkında fikir sahibi olacaklardır. Önceden öngörü elde edilmesi ile birçok olumsuz maliyetler engellenmiş olacak ve kaynaklar doğru yere aktarılacaktır. TÜİK verilerine göre 2017 yılında ülkemizde ihracatın % 56,6'sı ve ithalatın ise % 52,1'i sanayi sektöründe faaliyet gösteren işletmeler tarafından yapılmıştır. İhracatın yarısından fazlasının imalat sanayisinde yer alan girişimciler tarafından yapılmış olması bu sektörün ne derece önemli olduğunun bir göstergesidir. Bu sektörün güçlendirilmesi, henüz belli sıkıntılar oluşmadan tedbirlerin alınması gerekmektedir. Araştırmacıların çeşitli tahmin modelleri geliştirip, sanayi şirketlerinin sıkıntıya uğramadan önce önlemler almasını sağlamaları ülkelerin refah seviyesinin yükselmesine fayda sağlayacaktır.

Literatürde BİST imalat sanayi işletmelerinin başarısızlığının tahmininde, destek vektör makineleri ve ensemble öğrenme tekniklerinin kullanıldığı çalışmalar pek fazla bulunmamaktadır. Özellikle çalışmada oluşturulan ensemble öğrenme modelinin, yani YSA ve DVM gibi iki sınıflandırma algoritmasının bir arada kullanıldığı tahmin modelinin, BİST imalat sanayi şirketlerinin başarısızlığının tespitinde daha önce kullanılmamış olması, bu çalışmanın literatüre bir katkısı olarak değerlendirilebilir. Yapılan çalışmada elde edilen sonuçların geliştirilebilmesi için ileriki analizlerde diğer yapay zekâ yöntemlerinin ve diğer yapay zekâ yöntemlerinin (DVM, YSA ve karar ağaçları öğrenmesi gibi) bir arada kullanıldığı ensemble öğrenme yönteminin kullanılması önerilebilir.

KAYNAKÇA

- Abdel-Kader, M. G. ve Dugdale, D. (2001). Evaluating Investments in Advanced Manufacturing Technology: A Fuzzy Set Theory Approach. *The British Accounting Review*, 33(4), 455-489. doi: <https://doi.org/10.1006/bare.2001.0177>
- Affenzeller, M., Winkler, S., Wagner, S. ve Beham, A. (2009). *Genetic Algorithms and Genetic Programming Modern Concepts and Practical Applications* (Vol. 6). Almanya, Berlin: Taylor & Francis Group, LLC.
- Ađırman, E. (2018). Finansal Sıkıntı Göstergeleri: Bist'te İşlem Gören İmalat Sanayi Firmaları Üzerine Bir Araştırma. *Ataturk University Journal of Economics & Administrative Sciences*, 32(2).
- Ađyar, Z. (2015a). Yapay Sinir Ağlarının Kullanım Alanları ve Bir Uygulama. *Mühendis ve Makine Dergisi*, Sayı:662, 22-23.
- Ađyar, Z. (2015b). Yapay Zeka ve Sinir Ağları. <https://www.hostingdergi.com.tr/yapay-zeka-ve-sinir-aglari/>. (26.11.2018)
- Aizerman, M. A., Braverman, E. ve Rozonoer, L. (1964). Theoretical foundations of the potential function method in pattern recognition learning. *Automation and remote control*, 25, 821-837.
- Akbulut, R. ve Rençber, F. (2016). *Anfıs Yöntemi İle Finansal Başarısızlığın Tahmin Edilmesi: Bistte Ticaret Ve Hizmet Sektörü Üzerine BİR Uygulama*. Paper presented at the XVII. Uluslararası Ekonometri, Yöneylem Araştırması ve İstatistik Sempozyumu.
- Akcan, A. ve Kartal, C. (2011). İMKB Sigorta Endeksini Olusturan Sirketlerin Hisse Senedi Fiyatlarının Yapay Sinir Ağları İle Tahmini. *Muhasebe ve Finansman Dergisi*(51), 27-40.
- Akdağ, R. (2014). *Yapay Sinir Ağları Yöntemiyle Diyarbakır ili Kent Merkezi İçme Suyu Talep Tahmini Uygulaması*. (Yayınlanmamış Doktora Tezi), Dicle Üniversitesi, Diyarbakır.
- Akgüç, Ö. (1998). *Finansal Yönetim* (8 ed.). Avcıol Basım Yayın.
- Akgüç, Ö. (2011). *Mali Tablolarda Analizi*. İstanbul: Arayış Yayıncılık.
- Akgün , A. (2013). *Firmalarda Finansal Başarısızlığın Tahmini ve İstanbul Menkul Kıymetler Borsası'nda Bir Uygulama*. (Yayınlanmamış Doktora Tezi), Selçuk Üniversitesi, Konya.
- Akkaya, C. ve Tükenmez, M. (2007). İşletmelerde Finansal Yeniden Yapılanma Dinamikleri: Örnek Olay Analizi. *Dokuz Eylül Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 22(2).
- Akkaya, G. (2007). Yapay sinir ağları ve tarım alanındaki uygulamaları. *Atatürk Üniversitesi Ziraat Fakültesi Dergisi*, 38(2), 195-202.
- Akkaya , G., Demireli , E. ve Yakut , Ü. H. (2009). İşletmelerde finansal başarısızlık tahminlemesi: Yapay sinir ağları modeli ile İMKB üzerine bir uygulama. *Eskişehir Osmangazi Üniversitesi Sosyal Bilimler Dergisi*, 10(2).

- Akkoç, S. (2007). *Finansal Başarısızlığın Öngörülmesinde Sinirsel Bulanık Ağ Modelinin Kullanılması ve Ampirik Bir Çalışma*. (Doktora Tezi), Dumlupınar Üniversitesi, Kütahya.
- Akşehirli, Ö. Y., Ankaralı, H., Aydın, D. ve Saraçlı, Ö. (2013). Tıbbi Tahminde Alternatif Bir Yaklaşım: Destek Vektör Makineleri. *Türkiye Klinikleri Journal of Biostatistics*, 5(1), 19-28.
- Aksoy, B. (2018). *İşletmelerde Finansal Başarısızlık Tahmininde Veri Madenciliği Yöntemlerinin Karşılaştırılması: Bist'de Bir Uygulama* (Yayınlanmamış Doktora Tezi), Erciyes Üniversitesi, Kayseri.
- Aktan, C. C. ve Şen, H. (2001). Ekonomik kriz: Nedenler ve çözüm önerileri. *Yeni Türkiye Dergisi*(42), 1225-1231.
- Aktaş, R. (1993). *Endüstri İşletmeleri için Mali Başarısızlık Tahmini (Çok Boyutlu Model Uygulaması)*. Ankara: Türkiye İş Bankası Kültür Yayınları
- Aktaş, R., Doğanay, M. ve Yıldız, B. (2003). Mali başarısızlığın öngörülmesi: İstatistiksel yöntemler ve yapay sinir ağı karşılaştırılması. *Ankara Üniversitesi SBF Dergisi*, 58(04), 1-24.
- Alavala, C. R. (2008). *Fuzzy Logic And Neural Networks Basic Concepts & Applications*. India: New Age International (P) Limited, Publishers.
- Alcı, M. (2002). *Bulanık Mantık Ve Matlab Uygulamaları* (Vol. 1). İzmir.
- Alcı, M. ve Etçibaşı, T. (1998). Bulanık Mantık İle Fonksiyon Tanımlama. *Sakarya University Journal of Science*, 2(1), 21-24.
- Alifiah, M. N. (2014). Prediction of Financial Distress Companies in the Trading and Services Sector in Malaysia Using Macroeconomic Variables. *Procedia - Social and Behavioral Sciences*, 129, 90-98. doi: <https://doi.org/10.1016/j.sbspro.2014.03.652>
- Allahverdi, N. (2002). *Uzman Sistemler* (Vol. 1). İstanbul: Atlas Yayın Dağıtım.
- Altman, E. I. (1968). Financial Ratios, Discriminant Analysis and the Prediction of Corporate Bankruptcy. *The Journal of Finance*, 23(4), 589-609. doi: 10.2307/2978933
- Amemiya, T. (1981). Qualitative Response Models: A Survey. *Journal of Economic Literature*, 19(4), 1483-1536.
- Amendola, A., Giordano, F., Parrella, M. L. ve Restaino, M. (2017). Variable selection in high-dimensional regression: a nonparametric procedure for business failure prediction. *Applied Stochastic Models in Business and Industry*, 33(4), 355-368.
- Anthony, M. ve Bartlett, P. (2009). *Neural Network Learning: Theoretical Foundations*. United States of America: Cambridge University Press.
- Anwar, S. ve A.m, H. A. (2018). Anns-Based Early Warning System For Indonesian İslamic Banks. *Bulletin of Monetary Economics and Banking*, 20(3), 1-18.
- Argyrou, A. (2006). *Predicting financial distress using Neural Networks: Another episode to the serial*. (Yayınlanmamış yüksek lisans tezi).
- Arthtur, K., John, M., William, P. ve David, S. (2005). *Financial Management: Principles and Applications* (10 ed.): Pearson Prentice Hall.
- Arzu, A. ve Önder, H. (2013). Farklı Veri Yapılarında Kullanılabilecek Regresyon Yöntemleri. *Anadolu Tarım Bilimleri Dergisi*, 28(3), 168-174.
- Aslanoğlu, S., Özalp, A. D. ve Özalp, A. R. (2017). Bir Yeniden Yapılandırma Kurumu Olarak Konkordato Başvurusu, Geçici Mühlet Ve Gerekçeleri. *Ekonomi, İşletme, Siyaset ve Uluslararası İlişkiler Dergisi*, 3(2), 63-78.

- Atakan, C. ve Karabulut, İ. (2003). Derinliğe Dayalı Diskriminasyon. *Selçuk Üniversitesi Fen Fakültesi Fen Dergisi*, 1(22), 53-64.
- Atalay, O. (2018). İflas erteleme kötüye kullanıldı, konkordatoda da eski alışkanlıklar sürüyor., <http://www.hurriyet.com.tr/ekonomi/iflas-erteleme-kotuye-kullanildi-konkordatoda-da-eski-aliskanliklar-suruyor-40940072>.
- Ataseven, B. (2013). Yapay sinir ağları ile öngörü modellemesi. *Öneri Dergisi*, 10/39, 101-115.
- Atiya, A. F. (2001). Bankruptcy prediction for credit risk using neural networks: A survey and new results. *IEEE Transactions on neural networks*, 12(4), 929-935.
- Aydın , N., Başar , M. ve Coşkun , M. (2017). *Finansal Yönetim* (5 ed.). Ankara: Detay Yayıncılık.
- Aydın, O. (2013). *Yapay Zeka: Bütünleşik Bilişim Doğru* (Vol. 1). İstanbul: İstanbul Gelişim Üniversitesi Yayınları.
- Ayhan, S. ve Erdoğan, Ş. (2014). Destek Vektör Makineleriyle Sınıflandırma Problemlerinin Çözümü İçin Çekirdek Fonksiyonu Seçimi. *Eskişehir Osmangazi Üniversitesi İktisadi ve İdari Bilimler Dergisi*, 9(1), 175-198.
- Beaver , W. (1966). Financial Ratios As Predictors of Failure. *Journal of Accounting Research*, 4, 71-111. doi: 10.2307/2490171
- Beaver, W. H. (1968). Market prices, financial ratios, and the prediction of failure. *Journal of Accounting Research*, 179-192.
- Bench-Capon, T. J. M. ve Dunne, P. E. (2007). Argumentation in artificial intelligence. *Artificial Intelligence*, 171(10), 619-641. doi: <https://doi.org/10.1016/j.artint.2007.05.001>
- Berk, N. (2015). *Finansal yönetim* (Vol. 11. bs). İstanbul: Hiperlink.
- Berry, M. J. ve Linoff, G. (1997). *Data Mining Techniques: For Marketing, Sales, and Customer Support*. United States of America John Wiley & Sons, Inc.
- Bielawski, L. ve Lewand, R. (1991). *Intelligent Systems Design; Integrating Expert Systems, Hypermedia, and Database Technologies* Amerika Birleşik Devletleri: John Wiley & Sons, Inc. .
- Birgili, E., Sekmen, F. ve Esen, S. (2013). Bulanık Mantık Yaklaşımıyla Finansal Yönetim Uygulamaları: Bir Literatür Taraması. *Uluslararası Yönetim İktisat ve İşletme Dergisi*, 9(19), 121-136.
- Bolat, B., Erol, K. O. ve İmrak, C. E. (2004). Genetic algorithms in engineering applications and the Function of operators. *Sigma-Mühendislik ve Fen Bilimleri Dergisi*, 264-271.
- Bordes, A. (2010). *New Algorithms for Large-Scale Support Vector Machines*. (Doktora Tezi), l'Universitö Paris, Paris.
- Breiman, L. (1996). Bagging predictors. *Machine learning*, 24(2), 123-140.
- Brigham, E., F., ve Daves, P., R. (2007). *Intermediate Financial Management* (19 ed. Vol. 19.Baskı). USA: Thomson/South-Western.
- Brigham, E., F., ve Houston, J., F. (2007). *Fundamentals of Financial Management* (Vol. 8.Baskı). Cincinnati: Thomson Southwestern.
- Bulut, F. (2016). Sınıflandırıcı Topluluklarının Dengesiz Veri Kümeleri Üzerindeki Performans Analizleri. *Bilişim Teknolojileri Dergisi*, 9(2), 153-159.

- Businessht. (2017). Aktif kârlılık nasıl hesaplanır? Ne anlama gelir? , <https://businessht.bloomberght.com/piyasalar/haber/1583151-aktif-krlilik-nedir>. (25.05.2019)
- Çakır, M. (2005). *Firma Başarısızlığının Dinamiklerinin Belirlenmesinde Makine Öğrenme Teknikleri: Ampirik Uygulamalar ve Karşılaştırmalı Analiz*. (Uzmanlık Yeterlik Tezi), Ankara.
- Casey, C. ve Bartczak, N. (1985). Using operating cash flow data to predict financial distress: Some extensions. *Journal of Accounting Research*, 384-401.
- Çayıroğlu, İ. (2015). İleri Algoritma Analizi-5 Yapay Sinir Ağları. *Karabük Üniversitesi Mühendislik Fakültesi*.
- Cebeci, İ. (2012). Krizleri İncelemede Kullanılan Nitel Tercih Modelleri: Türkiye İçin Bir Probit Model Uygulaması (1988-2009). *İstanbul Üniversitesi İktisat Fakültesi Mecmuası*.
- Çelik, M. K. (2009). Finansal Başarısızlık Tahmin Modellerinden İMKB'deki Firmalar İçin Karşılaştırmalı Analizi. *Doktora Tezi*, 75-79.
- Ceylan, A. ve Korkmaz, T. (2015). *İşletmelerde Finansal Yönetim* (Vol. 14). Bursa: Ekin Yayınevi.
- Chen, J., Marshall, B. R., Zhang, J. ve Ganesh, S. (2006). Financial distress prediction in China. *Review of Pacific Basin Financial Markets and Policies*, 9(02), 317-336.
- Civalek, Ö. (1999). Dairesel Plakların Nöro-Fuzzy Tekniği İle Analizi. *Dokuz Eylül Üniversitesi Mühendislik Fakültesi Mühendislik Bilimleri Dergisi*, C1/S2, 1, 13-31.
- Civelekoğlu, G. (2006). *Arıtma Proseslerinin Yapay Zeka ve Çoklu İstatistiksel Yöntemler ile Modellenmesi* (Doktora Tezi), Süleyman Demirel Üniversitesi, Isparta.
- Clark, K. ve Ofek, E. (1994). Mergers as a Means of Restructuring Distressed Firms: An Empirical Investigation. *The Journal of Financial and Quantitative Analysis*, 29(4), 541-565. doi: 10.2307/2331109
- Çoban, Y. (2014). *İşletme İktisadi* (Vol. 1). 2014: On İki Levha Yayıncılık.
- Çomak, E. (2008). *Destek Vektör Makinelerinin Etkin Eğitimi İçin Yeni Yaklaşımlar*. (Yayınlanmamış Doktora Tezi), Selçuk Üniversitesi, Konya.
- Cortes, C. ve Vapnik, V. (1995). Support-vector networks. *Machine learning*, 20(3), 273-297.
- Coşkun, A. ve Arıcı, N. (2006). Genetik Algoritma Kullanılarak Deriden Geçiş Özelliklerine Göre Kimyasal Maddelerin Molekül Yapılarının Bulunması. *Politeknik Dergisi*, 9(4), 255-261.
- Çunkaş, M. (2006). Genetik Algoritmalar ve Uygulamaları. <http://www.horozerk.com/wp-content/uploads/genetic.pdf>. (13.11.2018)
- Dayı, F. (2015). *Finansal Yönetim* (Vol. 1.baskı). İstanbul: Beta Yayıncılık.
- De Bock, K. W., Coussement, K. ve Van den Poel, D. (2010). Ensemble classification based on generalized additive models. *Computational Statistics & Data Analysis*, 54(6), 1535-1546.
- Deakin, E. B. (1972). A discriminant analysis of predictors of business failure. *Journal of Accounting Research*, 167-179.
- Delice, G. (2003). Finansal Krizler: Teorik ve Tarihsel Bir Perspektif. *Erciyes Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*(20).

- Dirican, A. (2001). Tanı Testi Performanslarının Değerlendirilmesi Ve Kıyaslanması. *Cerrahpaşa Tıp Dergisi*, 32(1).
- Doğan, G. (2010). *Yapay Sinir Ağları Kullanılarak Türkiye'deki Özel Bir Sigorta Şirketinde Portföy Değerlendirmesi*. (Yayınlanmamış Yüksek Lisans Tezi), Hacettepe Üniversitesi, Ankara.
- Dogan, V. ve Yilmaz, C. (2017). Yönetim Bilimleri Ve Pazarlama Alanında Bağımsız Değişkenlerin Karşılaştırılması ve Bastırıcı Etki Tespiti. *Uluslararası Yönetim İktisat ve İşletme Dergisi*, 13(2), 385-406.
- Edmister, R. O. (1972). An empirical test of financial ratio analysis for small business failure prediction. *Journal of Financial and Quantitative analysis*, 7(2), 1477-1493.
- Edward, A. (2006). *Corporate Financial Distress and Bankruptcy* (Vol. Third).
- Ehrhardt, M. ve Brigham, E. (2011). *Financial Management: Theory and Practice* (Vol. 13.Baskı). USA: South-Western Cengage Learning.
- Ekinci, A. ve Erdal, H. İ. (2017). Forecasting bank failure: Base learners, ensembles and hybrid ensembles. *Computational Economics*, 49(4), 677-686.
- Elmas, Ç. (2007). *Yapay Zeka Uygulamaları* (Vol. 1). Ankara: Seçkin Yayıncılık A.Ş.
- Emel, G. G. ve Taşkın, Ç. (2002). Genetik Algoritmalar ve Uygulama Alanları. *Uludağ Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 21(1), 129-152.
- Emir, Ş. (2013). *Yapay Sinir Ağları ve Destek Vektör Makineleri Yöntemlerinin Sınıflandırma Performanslarının Karşılaştırılması: Borsa Endeks Yönünün Tahmini Üzerine Bir Uygulama*. (Doktora Tezi), İstanbul Üniversitesi, İstanbul.
- Ercan, K., Metin ve Ban, Ü. (2008). *Değere Dayalı İşletme Finansı (Finansal Yönetim)* (Vol. 3.baskı). Ankara: Gazi Kitabevi.
- Erdal, H. İ. (2011). *Destek Vektör Makineleri İle Tahmine Dayalı Modelleme Ve Bir Uygulama*. (Yayınlanmamış Doktora Tezi), İstanbul Üniversitesi, İstanbul.
- Ergin, E. (2009). *İşletmelerde Finansal Başarısızlık Olasılığının Erken Tanısı: İmkb Uygulaması*. (Doktora Yayınlanmamış Doktora Tezi), Kocaeli Üniversitesi, Kocaeli.
- Erol, U. (2017). Konkordato iflasa çözüm olur mu? , <http://www.milliyet.com.tr/yazarlar/prof-dr-erol-ulusoy/konkordato-iflasa-cozum-olur-mu--2391088/>. (07.09.2018)
- Ersöz, S. (1998). *Üretim Pazarlama Entegrasyonunda Uzman Sistemler*. (Doktora Tezi), Gazi Üniversitesi, Ankara.
- Eryeşil, K. ve İraz, R. (2012). *Liderlik tarzları ile örgütsel bağlılık arasındaki ilişkinin incelenmesine yönelik bir alan araştırması*. Selçuk Üniversitesi Sosyal Bilimler Enstitüsü.
- Fausett, L. (1994). *Fundamentals of Neural Networks: Architectures, Algorithms and Applications*. New Jersey: Prentice Hall.
- Feldstein, M. (1999). Self-protection for emerging market economies: National Bureau of Economic Research.
- Fiksel, J. ve Covello, V. (1986). Knowledge Systems, Expert Systems, And Risk Communication. In M. J. L., R. Ortwin, P. L. D. ve U. V. R. R. (Eds.), *Expert Judgment and Expert Systems* (Vol. 1). Portekiz: Springer-Verlag Berlin Heidelberg.

- Fine, T. L. (1999). *Feedforward Neural Network Methodology*: Springer Science & Business Media.
- Foreman, R. D. (2003). A logistic analysis of bankruptcy within the US local telecommunications industry. *Journal of Economics and Business*, 55(2), 135-166.
- Freund, R. ve Wilson, W. (2003). *Statistical Methods* (Vol. 2). ABD: Academic Press.
- Freund, Y. ve Schapire, R. E. (1997). A decision-theoretic generalization of on-line learning and an application to boosting. *Journal of computer and system sciences*, 55(1), 119-139.
- Gallo, C., Letizia, C. ve Stasio, G. (2005). *Artificial neural networks in financial modelling*. Paper presented at the XXXVI EWGFM International Meeting "European Working Group on Financial Mathematics", Brescia.
- Gençoğlu, Ü. (2014). *Finansal Tablolar Analizi*. Bursa: Aktüel Yayıncılık.
- Géron, A. (2017). *Hands-on machine learning with Scikit-Learn and TensorFlow: concepts, tools, and techniques to build intelligent systems* (Vol. 1). USA: "O'Reilly Media, Inc."
- Gilbert, L. R., Menon, K. ve Schwartz, K. B. (1990). Predicting bankruptcy for firms in financial distress. *Journal of Business Finance & Accounting*, 17(1), 161-171.
- Gökçe, O. ve Şahin, A. (2003). Yönetimde rol kavramı ve yönetsel roller.
- Gorunescu, F. (2011). *Data Mining Concepts, Models and Techniques* (Vol. 12). Verlag Berlin Heidelberg: Springer.
- Gözütok, S. ve Özdemir, O. N. (2004). Genetik algoritma yöntemi ile su şebekelerinde hidrolik kalibrasyonun geliştirilmesi. *Gazi Üniversitesi Mühendislik-Mimarlık Fakültesi Dergisi*, 19(2), 125-130.
- Graupe, D. (2007). *Principles Of Artificial Neural Networks* (2 ed. Vol. 6). USA: World Scientific Publishing Co. Pte. Ltd.
- Güner, N. ve Çomak, E. (2014). Lise öğrencilerinin matematik dersine yönelik tutumlarının bulanık mantık yöntemi ile incelenmesi. *Pamukkale Üniversitesi Mühendislik Bilimleri Dergisi*, Sayı 5, 189-196. doi: 10.5505/pajes.2014.07379
- Gunn, S. R. (1998). *Support Vector Machines For Classification And Regression* (Vol. 14): University of Southampton/Faculty of Engineering, Science and Mathematics School of Electronics and Computer Science.
- Günoğlu, K., Akkurt, İ., Yeğin, G. ve Tekin, H. (2011). Bremsstahlung Foton Akısının Yapay Sinir Ağı Kullanarak Modellenmesi. 153-156.
- Gupta, J., Barzotto, M. ve Khorasgani, A. (2018). Does size matter in predicting SMEs failure? *International Journal of Finance & Economics*, 23(4), 571-605.
- Guyon, I., Boser, B. ve Vapnik, V. (1993). *Automatic capacity tuning of very large VC-dimension classifiers*. Paper presented at the Advances in neural information processing systems.
- Guyton, A. ve Hall, J. (2006). *Textbook of medical physiology*, 11th: Elsevier Inc.
- Hair, J., Black, W., Babin, B. ve Anderson, R. (2014). *Multivariate Data Analysis* (Vol. 7. Baskı). USA: Pearson Education Limited.
- Hamzaçebi, C. (2011). *Yapay Sinir Ağları*. Bursa: Ekin Basım Yayın Dağıtım.

- Hamzaçebi, C. ve Kutay, F. (2004). Yapay sinir ağları ile türkiye elektrik enerjisi tüketiminin 2010 yılına kadar Tahmini. *Gazi Üniversitesi Mühendislik-Mimarlık Fakültesi Dergisi*, 19(3).
- Han, J., Pei, J. ve Kamber, M. (2011). *Data mining: concepts and techniques* (2 ed.). USA: Elsevier.
- Hanrahan, G. (2011). *Artificial Neural Networks In Biological And Environmental Analysis*. USA: Taylor & Francis Group, an informa business.
- Härdle, W. ve Simar, L. (2007). *Applied Multivariate Statistical Analysis* (Vol. 2). Berlin, Germany: Springer.
- Harrington, P. (2012). *Machine learning in action*. USA: Shelter Island, NY: Manning Publications Co.
- Hastie, T., Tibshirani, R. ve Friedman, J. (2009). *The Elements Of Statistical Learning-Data Mining, Inference, and Prediction*: Springer.
- Haykin, S. (1999). *Neural Networks and Learning Machines* (Vol. 3). United States of America: Pearson Education, Inc.
- Hecht-Nielsen, R. (1989). Neurocomputer applications *Neural computers* (pp. 445-453): Springer.
- Hemmer, M. (2008). *Expert Systems in Chemistry Research*. New York: CRC Press.
- Holland, J. H. (1975). Adaptation in natural and artificial systems: an introductory analysis with applications to biology, control, and artificial intelligence: University of Michigan Press Ann Arbor.
- Hopfield, J. J. (1982). Neural networks and physical systems with emergent collective computational abilities. *Proceedings of the national academy of sciences*, 79(8), 2554-2558.
- Horta, I. M. ve Camanho, A. S. (2013). Company failure prediction in the construction industry. *Expert Systems with Applications*, 40(16), 6253-6257. doi: <https://doi.org/10.1016/j.eswa.2013.05.045>
- <https://en.wikipedia.org>. (2008). Logistic-curve.svg. <https://en.wikipedia.org/wiki/File:Logistic-curve.svg>. (9.11.2018)
- Huang, T.-M., Kecman, V. ve Kopriva, I. (2006). *Kernel based algorithms for mining huge data sets* (Vol. 1): Springer.
- İçen, D. ve Günay, S. (2014). Uzman Sistemler ve İstatistik. *İstatistikçiler Dergisi: İstatistik&Aktüerya*, 7, 37-45.
- İçerli, M. Y. ve Akkaya, G. C. (2006). Finansal Açıdan Başarılı Olan İşletmelerle Başarısız Olan İşletmeler Arasında Finansal Oranlar Yardımıyla Farklılıkların Tespiti. *Atatürk Üniversitesi İktisadi ve İdari Bilimler Dergisi*, 20(1), 413-421.
- İliman, T. ve Tekeli, R. (2016). Türkiye'deki Düzenleyici ve Denetleyici Kuruluşlar: İdari Para Cezalarının Hukuksal Zeminlerinin Değerlendirilmesi. *Adnan Menderes Üniversitesi Sosyal Bilimler Enstitüsü Dergisi*, 3(1), 23-36.
- İnal, M. E., Topuz, D. ve Okyay, U. (2006). Doğrusal Olasılık ve Logit Modelleri ile Parametre Tahmini. *Sosyoekonomi*, 3(3).
- İnceyol, Y. (2014). *Arazi Düzenleme Çalışmalarında Genetik Algoritma Uygulaması*. (Yayınlanmamış Doktora Tezi), Selçuk Üniversitesi, Konya.
- Jo, H., Han, I. ve Lee, H. (1997). Bankruptcy prediction using case-based reasoning, neural networks, and discriminant analysis. *Expert Systems with Applications*, 13(2), 97-108.

- Joy, O. M. ve Tollefson, J. O. (1975). On the Financial Applications of Discriminant Analysis. *The Journal of Financial and Quantitative Analysis*, 10(5), 723-739. doi: 10.2307/2330267
- Kantardzic, M. (2011). *Data mining: concepts, models, methods, and algorithms* (2 ed.). USA: John Wiley & Sons.
- Karaca, C. ve Alsu, E. (2017). İşletmelerde Ticari Alacak ve Borç Politikasının Belirleyicileri: BIST İmalat Sanayii üzerinde Ekonometrik Bir Uygulama. 5, 146-165. doi: 10.18301/rss.478
- Karacan, S. ve Savcı, M. (2011). Kriz Dönemlerinde İşletmelerin Mali Başarısızlık Nedenleri. *Kocaeli Üniversitesi Sosyal Bilimler Enstitüsü Dergisi*(21), 39-54.
- Karasoy, O. ve Ballı, S. (2016). *Google Maps ve Genetik Algoritmalarla GSP Çözümü İçin Öneri*. Paper presented at the 18. Akademik Bilişim Konferansı, Adnan Menderes Üniversitesi, Aydın. <https://ab.org.tr/ab16/sunum/202.pdf>
- Karush, W. (1939). Minima of functions of several variables with inequalities as side constraints. *M. Sc. Dissertation. Dept. of Mathematics, Univ. of Chicago*.
- Kaya, T. ve İnce, M. (2011). *Genetik Algoritma Yardımıyla Elde Edilen Yüksek Performanslı Pencere Fonksiyonlarının Yinelemesiz Sayısal Filtre Tasarımında Kullanımı*. Paper presented at the 6th International Advanced Technologies Symposium-IATS.
- Kaygın, C., Tazegül, A. ve Yazarkan, H. (2016). İşletmelerin Finansal Başarılı ve Başarısız Olma Durumlarının Veri Madenciliği ve Lojistik Regresyon Analizi İle Tahmin Edilebilirliği. *Ege Academic Review*, 16(1).
- Kaytez, F. (2012). *En Küçük Kareler Destek Vektör Makineleri İle Türkiye'nin Uzun Dönem Elektrik Tüketim Tahmini Ve Modellemesi*. (Yayınlanmamış Doktora Tezi), Gazi Üniversitesi, Ankara.
- Kazbek, A. (2015). *Finansal Tablolar Okuryazarlığı*. Adana: Karahan Kitapevi.
- Keçeoğlu, Ç. R., Gelbal, S. ve Doğan, N. (2016). Roc Eğrisi Yöntemi İle Kesme Puanının Belirlenmesi. *The Journal of Academic Social Science Studies*, 553-562. doi: <http://dx.doi.org/10.9761/JASSS3564>
- Kecman, V. (2001). *Learning and soft computing: support vector machines, neural networks, and fuzzy logic models*. London: MIT press.
- Keeney, R. (1986). Value-Driven Expert Systems For Decision Support In M. J. L., R. Ortwin, P. L. D. ve U. V. R. R. (Eds.), *Expert Judgment and Expert Systems* (Vol. 1). Portekiz: Springer-Verlag Berlin Heidelberg.
- Kelly, D. L. ve LeRoy, S. F. (2007). Liquidity and Liquidation. *Economic Theory*, 31(3), 553-572. doi: 10.1007/s00199-006-0113-7
- Kenneth, M. ve Christian, W. (1986). Expert Systems And Creativity In M. J. L., R. Ortwin, P. L. D. ve U. V. R. R. (Eds.), *Expert Judgment and Expert Systems* (Vol. 1). Portekiz: Springer-Verlag Berlin Heidelberg.
- Keskin, Y. (2002). *İşletmelerde Finansal Başarısızlığın Tahmini, Çok Boyutlu Model Önerisi Ve Uygulaması*. (Doktora Tezi), Hacettepe Üniversitesi, Ankara.
- Kevran, M. M. (2009). *Çoklu Sensör Konumlandırma Probleminin Genetik Algoritmalar İle Çözülmesi*. (Yayınlanmamış Yüksek Lisans Tezi), Hava Harp Okulu Komutanlığı, YEŞİLYURT - İSTANBUL.
- Khare, M. ve Nagendra, S. M. S. (2007). *Artificial Neural Networks in Vehicular Pollution Modelling*. Berlin: Springer-Verlag Berlin Heidelberg.
- Kibritçioğlu, A. (2001). *Türkiyede Ekonomik Krizler ve Hükümetler, 1969-2001*.

- Kılıç, S. (2013). ROC Analysis in Clinical Decision Making. *Journal of Mood Disorders*, 3(3), 135.
- Kılıç Topal, K. (2015). *Genetik Algoritmaya Dayalı Yeni Bir Sağlam Korelasyon Katsayısı*. (Yayınlanmamış Yüksek Lisans Tezi), Ondokuz Mayıs Üniversitesi, Samsun.
- Kılıç , Y. (2011). Finansal Başarısızlık Tahmininde Veri Madenciliğinin Kullanılması: İmkb'de Bir Uygulama. *Yayımlanmamış Yüksek Lisans Tezi, Gaziantep Üniversitesi, Sosyal Bilimler Enstitüsü, Gaziantep*.
- Kılıç , Y. ve Seyrek, İ. H. (2012). *Finansal Başarısızlık Tahmininde Yapay Sinir Ağlarının Kullanılması: İmalat Sektöründe Bir Uygulama. ISAF 2012*. Paper presented at the 1st International Symposium on Accounting and Finance (Tam Metin Bildiri/Sözlü Sunum)(Yayın No: 3438181).
- Kıyak, E. ve Kahvecioğlu, A. (2003). Bulanık Mantık Ve Uçuş Kontrol Problemine Uygulanması. *Journal of Aeronautics and Space Technologies*, 1(2), 63-72.
- Koh, C. H. ve Low, K. C. (2004). Going concern prediction using data mining techniques. *Managerial Auditing Journal*, 19(3), 462-476.
- Kohonen, T. (1982). Self-organized formation of topologically correct feature maps. *Biological cybernetics*, 43(1), 59-69.
- Küçükkocaoğlu, G., Benli, Y. K. ve Küçüksözen, C. (2007). Finansal bilgi manipülasyonunun tespitinde yapay sinir ağı modelinin kullanımı. *İMKB Dergisi*, 9(36), 1-30.
- Kuhn, H. (1951). *AW Tucker, Nonlinear Programming*. Paper presented at the Proceedings of the 2nd Berkeley Symposium on Mathematical Statistics and Probability.
- Kutman, Ö. (2001). Türkiye'deki şirketlerde erken uyarı göstergelerinin araştırılması. *Doğuş Üniversitesi Dergisi*, 2(2), 59-70.
- Langley, P. (2000). *Crafting papers on machine learning*. Paper presented at the ICML.
- Law, M. (2018). An Introduction to Support Vector Machines. http://www.cs.nccu.edu.tw/~whliao/pr2008/intro_SVM.ppt. (11.12.2018)
- Lee, W.-C. (2008). An empirical comparison of bankruptcy models: Evidence from Taiwan. *Sigorta Aktüerya Bilim ve İstatistiklerine İlişkin 4. Akademik Seminer*, 6, 149-168.
- Maddala, G. S. (1992). *Introduction to Econometrics* (Vol. 2). New York: Macmillan Publishing Company.
- Makridakis, S. (2017). The forthcoming Artificial Intelligence (AI) revolution: Its impact on society and firms. *Futures*, 90, 46-60. doi: <https://doi.org/10.1016/j.futures.2017.03.006>
- Marczyk, A. (2004). Genetic Algorithms and Evolutionary Computation. <http://www.talkorigins.org/faqs/genalg/genalg.html>. (17.11.2018)
- Meriç, O. A. (2004). *Veri Madenciliği Aracı Olarak Genetik Algoritmalar İle Yapay Sinir Ağları ve Genetik Algoritma-Yapay Sinir Ağı Melez Modelinin Müşteri Değerlendirilmesinde Kullanılması*. (Doktora Tezi), İstanbul Üniversitesi, İstanbul.
- Merwin, C. L. (1942). *Financing small corporations in five manufacturing industries, 1926-1936*: National Bureau of Economic Research, New York.
- Mishkin, F. S. (2007). *The economics of money, banking, and financial markets*: Pearson education.

- Moharrampour, M., Sara, E. ve Asgarzadeh, A. (2014). Evaluating the Bankruptcy prediction models. *Applied mathematics in Engineering, Management and Technology*, 2(3), 620-633.
- Nguyen, H. G. (2005). Using neural network in predicting corporate failure. *Journal of Social Sciences*, 1(4), 199-202.
- Ngwenya, S. (2018). Assessing the State of Financial Distress of Listed Gold and Platinum Mining Companies in South Africa. *Acta Universitatis Danubius. OEconomica*(14(4)), 655-677.
- Öcal, N. ve Kadioğlu, E. (2015). *Finansal Başarısızlığın Tahmini: Borsa İstanbul'da İmalat Sektörü İçin Bir Uygulama*. Paper presented at the 19. Finans Sempozyumu, Çorum.
- Odom, M. D. ve Sharda, R. (1990). *A neural network model for bankruptcy prediction*. Paper presented at the Neural Networks, 1990., 1990 IJCNN International Joint Conference on.
- Ohlson, J. (1980). Financial Ratios And The Probabilistic Prediction Of Bankruptcy. *Journal of Accounting Research*, 18(1), 109-131.
- Okka, O. (2015). *Analitik Finansal Yönetim* (Vol. 2). İstanbul: Nobel Akademik Yayıncılık.
- Okutmuşur, B. (2005). *Reproducing Kernel Hilbert Spaces*. (Yayınlanmamış Yüksek Lisans Tezi), Bilkent Üniversitesi, Ankara.
- Orhun, E. (1986). Expert Systems And Intelligent Computer-Assisted-Instruction. In M. J. L., R. Ortwin, P. L. D. ve U. V. R. R. (Eds.), *Expert Judgment and Expert Systems* (Vol. 1). Portekiz: Springer-Verlag Berlin Heidelberg.
- Oruç, K. O. ve Yılmaz, G. (2013). Bulanık 0-1 Tamsayı Programlama Ve Bir Hazır Beton Tesisinde Uygulama. *Süleyman Demirel Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 18(3), 245-262.
- Öz, B., Ayriçay, Y. ve Kalkan, G. (2011). Finansal oranlarla hisse senedi getirilerinin tahmini: İMKB 30 endeksi hisse senetleri üzerine diskriminant analizi ile bir uygulama.
- Özdamar, K. (2013). *Paket Programlar İle İstatistiksel Veri Analizi (Cilt 1)* (Vol. 9.Baskı). Eskişehir: Nisan Kitapevi.
- Özdemir, M. (2016). *Finansal yönetim* (Vol. 3. basım). İstanbul: İstanbul.
- Özkan, F. (2011). Döviz Kuru Tahmininde Yapay Sinir Ağlarıyla Alternatif Yaklaşım. *Eskişehir Osmangazi Üniversitesi İktisadi ve İdari Bilimler Dergisi*, 6(2), 185-200.
- Özkanlı, S. (2011). *İşletmelerde Finansal Sıkıntı Durumu Ve Finansal Yeniden Yapılandırma: Türkiyede Bir Vaka Çalışması*. (Doktora Tezi), Çukurova Üniversitesi, Adana.
- Ozkop, E., Altas, İ. ve Akpınar, A. (2004). *Bulanık Mantık Denetleyicili Güç Sistem Uygulaması*. Paper presented at the Elektrik-Elektronik ve Bilgisayar Mühendisliği Sempozyumu Bursa.
- Öztemel, E. (2016). *Yapay Sinir Ağları* (Vol. 4.basım). İstanbul: Papatya Yayıncılık.
- Öztürk, E. (2002). *İşletmelerde Mali Başarısızlık Nedenleri ve Alınabilecek Önlemler*. (Yüksek Lisans Tezi), Cumhuriyet Üniversitesi, Sivas.
- Özün, A. (2011). *Yapay Sinir Ağları ile Risk Öngörüsü*. (Yayınlanmamış Doktora Tezi), Marmara Üniversitesi, İstanbul.
- Pıçak, M., Yılmaz, S. ve Giray, Y. (2009). Küresel Ekonomik Sistemde Finansal Krizleri Önleme Ve Yönetme Sorunsalı

Mevzuat Dergisi, 12(137).

- Pompe, P. ve Feelders, A. (1997). Using machine learning, neural networks, and statistics to predict corporate bankruptcy. *Computer-Aided Civil and Infrastructure Engineering*, 12(4), 267-276.
- Provost, F. J., Fawcett, T. ve Kohavi, R. (1998). *The case against accuracy estimation for comparing induction algorithms*. Paper presented at the ICML.
- Pulat, M. ve Deveci, K. (2016). Gezin Satıcı Probleminin Genetik Algoritmalar Kullanarak Çözümünde Çaprazlama Operatörlerinin Örnek Olaylar Bazlı İncelenmesi. *Yöneylem Araştırması Endüstri Mühendisliği 36. Ulusal Kongresi*, 1-27.
- Radelet, S. ve Sachs, J. (1998). The onset of the East Asian financial crisis: National bureau of economic research.
- Rafique, Q. ve Al Mamun, A. (2015). *Corporate Failure Prediction of Public Listed Companies in Malaysia* (Vol. 91).
- Rokach, L. (2010). *Pattern classification using ensemble methods* (Vol. 75). USA: World Scientific.
- Romem, Y. (2010). Darwin, Culture and Expert Systems. In P. Vitureanu (Ed.), *Expert Systems*. Hindistan: Intech.
- Sabuncuoğlu, Z. ve Tokol, T. (2009). *İşletme*. Bursa: Furkan Ofset.
- Sachs, J. D. (1996). Alternative approaches to financial crises in emerging markets. *Revista de Economia Politica*, 16, 40-52.
- Salur, M., Nuri. (2015). *İşletmelerde Finansal Başarısızlık Tahmini ve Yapay Sinir Ağları Modelinin Kullanımı: Borsa İstanbul'da Bir Uygulama*. (Doktora Tezi), Marmara Üniversitesi, İstanbul.
- Sayılgan, G. (2013). *Soru ve Yanıtlarla İşletme Finansmanı*. Ankara: Turhan Kitapevi.
- Sayılgan, G. ve Coşkun, E. (2009). Finansal Sıkıntılı Şirketlerde Yeniden Yapılandırma Süreçleri ve Yeniden Yapılandırma Süreçlerinin Seçimini Etkileyen Faktörler. *Ankara Üniversitesi SBF Dergisi*, 64(02), 145-162.
- Schmalhofer, F. (1986). Expert Systems As Cognitive Tools For Human Decision Making In M. J. L., R. Ortwin, P. L. D. ve U. V. R. R. (Eds.), *Expert Judgment and Expert Systems* (Vol. 1). Portekiz: Springer-Verlag Berlin Heidelberg.
- Scholkopf, B. ve Smola, A. J. (2001). *Learning with kernels: support vector machines, regularization, optimization, and beyond*. USA: MIT press.
- Scott, J. (1981). The probability of bankruptcy: A comparison of empirical predictions and theoretical models. *Journal of Banking & Finance*, 5(3), 317-344. doi: [https://doi.org/10.1016/0378-4266\(81\)90029-7](https://doi.org/10.1016/0378-4266(81)90029-7)
- Şeker, Ş. E. (2008). İleri Beslemeli Ağlar (Feedforward Neural Networks). <http://bilgisayarkavramlari.sadievrenseker.com/2008/11/02/ileri-beslemeli-aglar-feedforward-neural-networks/>. (30.11.2018)
- Şeker, Ş. E. (2009). Mutasyon. <http://bilgisayarkavramlari.sadievrenseker.com/2009/02/17/mutasyon-tehavvulmutation/>. (14.11.2018)
- Selimoğlu, S. ve Orhan, A. (2015). Finansal başarısızlığın oran analizi ve diskriminant analizi kullanılarak ölçülmesi: BİST'de işlem gören dokuma, giyim eşyası ve deri işletmeleri üzerine bir araştırma. *Muhasebe ve Finansman Dergisi*(66), 21-40.

- Şen, Z. (2010). *Fuzzy Logic and Hydrological Modeling*. New York: CRC Press is an imprint of Taylor & Francis Group, an Informa business.
- Seni, G. ve Elder, J. F. (2010). *Ensemble methods in data mining: improving accuracy through combining predictions* (Vol. 2): Morgan & Claypool Publishers series.
- Serhatlioğlu, S. ve Hardalaç, F. (2009). Yapay Zeka Teknikleri ve Radyolojiye Uygulanması. *Fırat Tıp Dergisi*, 14(1), 001-006.
- Sharma, S. (1996). *Applied Multivariate Techniques*. Amerika Birleşik Devletleri: John Wiley & Sons, Inc. .
- Sharma, S. ve Mahajan, V. (1980). Early Warning Indicators of Business Failure. *Journal of Marketing*, 44(4), 80-89. doi: 10.2307/1251234
- Shrivastava, A., Kumar, K. ve Kumar, N. (2018). Business Distress Prediction Using Bayesian Logistic Model for Indian Firms. *Risks*, 6(4), 1-15.
- Siler, W. ve Buckley, J. (2005). *Fuzzy Expert Systems And Fuzzy Reasoning*. Amerika Birleşik Devletleri: JOHN WILEY & SONS, INC.
- Sinan, A. (2009). Financial failure forecast by option pricing method: A Turkish case. *Investment Management and Financial Innovations*, 6(4), 177-187.
- Sinke, J. F. ve Walker, D. A. (1974). *Problem banks: Identification and characteristics*: Federal Deposit Insurance Corporation.
- Söylemez, Y. ve Türkmen, Y., Sibel. (2017). Yapay Sinir Ağları Modeli İle Finansal Başarısızlık Tahmini. *Finans Ekonomi ve Sosyal Araştırmalar Dergisi (FESA)*, Cilt:2 Sayı:4, 270-284. doi: 10.29106/fesa.364323
- Suarez, J. J. (2004). *A neural network model to predict business failure in construction companies in the United States of America*. University of Florida.
- Subaşı, S., Beycioğlu, A. ve Çullu, M. (2010). Bulanık Mantık Ve İstatistiksel Analiz Yöntemleri İle Revizyon Uygulanmış Betonlarda Basınç Dayanımı Tahmini. *SDU International Journal of Technological Science*, 2(3).
- Suykens, J. A., Gestel, J. V., Brabanter, J. D., Moor, B. D. ve Vandewalle, J. (2005). *Least Squares Support Vector Machine Classifiers* (Vol. 9). USA: World Scientific Publishing Co. Pte. Ltd.
- Tetik, Y. E. ve Bolat, B. (2011). *Gürültülü Ortamlarda Konuşma Tespiti İçin Yeni Bir Öznitelik Çıkarım Yöntemi*. Paper presented at the Elektrik-Elektronik ve Bilgisayar Sempozyumu, Fırat Üniversitesi, Elazığ.
- Torun, S. (2008). *Destek Vektör Makineleri: Banka Başarısızlığının Tahmini Üzerine Bir Uygulama*. (Yayınlanmamış Doktora Tezi), İstanbul Üniversitesi, İstanbul.
- Torun, T. (2007). *Finansal Başarısızlık Tahmininde Geleneksel İstatistiksel Yöntemlerle Yapay Sinir Ağlarının Karşılaştırılması Ve Sanayi İşletmeleri Üzerinde Uygulama*. (Doktora Tezi), Erciyes Üniversitesi, Kayseri.
- Triantaphyllou, E. (2000). *Multi-Criteria Decision Making Methods: A Comparative Study* Baton Rouge, Louisiana, US.A. : SPRINGER-SCIENCE+BUSINESS MEDIA B.V. .
- Tu, J. V. (1996). Advantages And Disadvantages Of Using Artificial Neural Networks Versus Logistic Regression For Predicting Medical Outcomes. *Journal of clinical epidemiology*, 49(11), 1225-1231.
- Türk, E. (2016). Limited Şirketlerin Sona Ermesi Ve Tasfiyesi. <http://www.sanayigazetesi.com.tr/limited-sirketlerin-sona-ermesi-ve-tasfiyesi-makale,913.html>.

- Türksoy, A. (2007). Konaklama İşletmelerinde Mali Başarısızlığa Yol Açan Etmenler. *Ege Akademik Bakış/Ege Academic Review*, 7(1), 2007.
- Udrescu, M. ve Ilie, C. (2009). New techniques applied in economics. artificial neural network. *Annals of Faculty of Economics*, 4(1), 1080-1084.
- Uğur, A. ve Kınacı, A. C. (2006). Yapay zeka teknikleri ve yapay sinir ağları kullanılarak web sayfalarının sınıflandırılması. *XI. Türkiye'de İnternet Konferansı (inet-tr'06), Ankara*, 1-4.
- Ünsal, A. (2001). Mali Başarılı Ve Mali Başarısız Şirketlerin Ayırımını Sağlayan Diskriminant Fonksiyonunun Bulunması. *Çukurova Üniversitesi Sosyal Bilimler Enstitüsü Dergisi*, 7(7), 214-234.
- Ural, Ş. (2010). Puslu (Fuzzy) Mantık. <https://www.safakural.com/makaleler/puslu-%28fuzzy%29-mantik>. (11.07.2018)
- Usta, Ö. (2014). *İşletme Finansı ve Finansal Yönetim* (Vol. 6). Ankara: Detay Yayıncılık.
- Uzun, E. (2005). İşletmelerde finansal başarısızlığın teorik olarak irdelenmesi. *Muhasebe ve Finansman Dergisi*(27), 158-168.
- Vapnic, V. N. (1998). *Statistical learning theory*. United States of America: John Wiley & Sons, Inc.
- Vapnik, V. ve Lerner, Y. (1963). Pattern recognition using generalized portrait method. *Automation and remote control*, 24, 774-780.
- Virág, M. ve Nyitrai, T. (2014). The application of ensemble methods in forecasting bankruptcy. *Financial and Economic Review*, 13(4), 178-193.
- Walter, J. E. (1957). Determination of Technical Solvency. *The Journal of Business*, 30(1), 30-43.
- wikipedia. (2018). Turing Testi. https://tr.wikipedia.org/wiki/Turing_testi. (05.11.2018)
- Wruck, K. H. (1990). Financial distress, reorganization, and organizational efficiency. *Journal of financial economics*, 27(2), 419-444.
- Wu, D. D., Liang, L. ve Yang, Z. (2008). Analyzing the financial distress of Chinese public companies using probabilistic neural networks and multivariate discriminate analysis. *Socio-Economic Planning Sciences*, 42(3), 206-220.
- Xu, X. ve Wang, Y. (2009). Financial failure prediction using efficiency as a predictor. *Expert Systems with Applications*, 36(1), 366-373. doi: <https://doi.org/10.1016/j.eswa.2007.09.040>
- Yakut, E. (2012). *Veri madenciliği tekniklerinden C5.0 algoritması ve destek vektör makineleri ile yapay sinir ağlarının sınıflandırma başarılarının karşılaştırılması: İmalat sektöründe bir uygulama*. (Doktora Tezi), Atatürk Üniversitesi, Erzurum.
- Yavuz, M. (2018). Son Düzenlemeler Işığında Mahkemelerce Verilen Konkordato Mühletinin Alacaklılar Ve Borçlu Bakımından Sonuçları. *Mali Çözüm Dergisi*, 28, 159-168.
- Yegnanarayana, B. (2005). *Artificial Neural Networks*. India: Asoke K. Ghosh, Prentice-Hall of India Private Limited,.
- Yıldırım, M. Z. (2017). *Makine Öğrenmesi Yöntemleri İle Network Üzerinde Saldırı Tespiti*. (Yayımlanmamış Yüksek Lisans Tezi), Karabük Üniversitesi, Karabük.

- Yıldız, B. (1999). *Finansal Başarısızlığın Öngörülmesinde Yapay Sinir Ağı Kullanımı Ve Ampirik Bir Çalışma*. (Yayınlanmamış Doktora Tezi), Dumlupınar Üniversitesi, Kütahya.
- Yıldız, B. (2009). *Finansal Analize Yapay Zeka* (Vol. 1.Baskı). Ankara: Detay Yayıncılık.
- Yurtoglu, H. (2005). *Yapay sinir ağıları metodolojisi ile öngörü modellemesi: Bazı makroekonomik değişkenler için Türkiye örneği* (Basilmamıs DPT Uzmanlık Tezi), Ankara.
- Zadeh, L. A. (1965). Fuzzy sets. *Information and Control*, 8(3), 338-353. doi: [https://doi.org/10.1016/S0019-9958\(65\)90241-X](https://doi.org/10.1016/S0019-9958(65)90241-X)
- Zeytinoglu, E. ve Akarim, Y. D. (2013). Financial failure prediction using financial ratios: An empirical application on Istanbul Stock Exchange. *Journal of Applied Finance and Banking*, 3(3), 107.
- Zeyveli, M. (2007). Genetik Algoritmalar Ve Mekanik Tasarım Problemleri Uygulamaları. *Makine Teknolojileri Elektronik Dergisi*, 2, 1-13.
- Zhang, G., Hu, M. Y., Patuwo, B. E. ve Indro, D. C. (1999). Artificial neural networks in bankruptcy prediction: General framework and cross-validation analysis. *European journal of operational research*, 116(1), 16-32.
- Zhang, L., Altman, E. I. ve Yen, J. (2010). Corporate financial distress diagnosis model and application in credit rating for listing firms in China. *Frontiers of Computer Science in China*, 4(2), 220-236. doi: 10.1007/s11704-010-0505-5
- Zheng, G. (2002). Analyzing bankruptcy in the restaurant industry: A multiple discriminant model. *International Journal of Hospitality Management*, 21(1), 25-42.
- Zheng, N. ve Xue, J. (2009). *Statistical learning and pattern analysis for image and video processing*: Springer Science & Business Media.
- Zmijewski, M. E. (1984). Methodological issues related to the estimation of financial distress prediction models. *Journal of Accounting Research*, 59-82.
- 6102 Sayılı Türk Ticaret Kanunu, Madde 376

ÖZGEÇMİŞ

Muhammed Fatih Yürük 1976 tarihinde Diyarbakır'da doğdu. İlk, orta, lise eğitimini Diyarbakır'da tamamladı. 1998 yılında Dicle Üniversitesi fizik bölümünden mezun oldu. 2007 yılında Eğitim Yönetimi alanında yüksek lisans yaptı. Daha sonra Ahmet Yesevi Üniversitesi Bilgisayar Mühendisliği ve Endüstri Mühendisliği lisans programlarından mezun oldu. 1999 yılında çalışma hayatına başladığı Milli Eğitim Bakanlığında 10 yıl öğretmen olarak çalıştı. 2009 yılında Mardin Artuklu Üniversitesinde Bilgi İşlem Daire Başkanlığı görevine getirildi. 1.5 yıl sonra aynı üniversitede Sosyal Bilimler Enstitüsü Sekreteri olarak göreve devam etti ve halen bu görevini sürdürmekte, İngilizce bilmektedir.

VITAE

Muhammed Fatih Yürük was born in 1976 in Diyarbakır. He completed his primary, secondary and high school education in Diyarbakır. In 1998 he graduated from the physics department at Dicle University. In 2007, he received his master's degree in Educational Administration. Then, he graduated from Ahmet Yesevi University Computer Engineering and Industrial Engineering programs. In 1999, he started working at the Ministry of Education for 10 years worked as a teacher. In 2009, he was appointed as the Head of Information Technology Department of Mardin Artuklu University. After working as a secretary of the Institute of Social Sciences in the same university, he still continues to hold this position and speaks English.

EKLER

EK A. Başarılı Firmalar Listesi

No	Şirket	Dönem	Başarı Durumu
1	ADANA	2015	1
2	ADBGR	2015	1
3	ADEL	2015	1
4	ADNAC	2015	1
5	AKCNS	2015	1
6	AKSA	2015	1
7	ALCAR	2015	1
8	ALKA	2015	1
9	ALKIM	2015	1
10	ANACM	2015	1
11	ARCLK	2015	1
12	ARSAN	2015	1
13	ASUZU	2015	1
14	AVOD	2015	1
15	AYGAZ	2015	1
16	BAGFS	2015	1
17	BAKAB	2015	1
18	BASCM	2015	1
19	BNTAS	2015	1
20	BOLUC	2015	1
21	BOSSA	2015	1
22	BRISA	2015	1
23	BRSAN	2015	1
24	BSOKE	2015	1
25	BTCIM	2015	1
26	BUCIM	2015	1
27	COLA	2015	1
28	CELHA	2015	1
29	CEMTS	2015	1
30	CIMSA	2015	1
31	CMENT	2015	1
32	COMDO	2015	1
33	CUSAN	2015	1

EK A. Başarılı Firmalar Listesi (Devamı)

34	DAGI	2015	1
35	DERIM	2015	1
36	DMSAS	2015	1
37	DOBUR	2015	1
38	DYOBY	2015	1
39	EGEEN	2015	1
40	EGGUB	2015	1
41	EGPRO	2015	1
42	EGSER	2015	1
43	ERBOS	2015	1
44	EREGL	2015	1
45	FMIZP	2015	1
46	FROTO	2015	1
47	GEDZA	2015	1
48	GENTS	2015	1
49	GOLTS	2015	1
50	GOODY	2015	1
51	GUBRF	2015	1
52	HEKTS	2015	1
53	IHEVA	2015	1
54	ISDMR	2015	1
55	IZFAS	2015	1
56	IZOCM	2015	1
57	JANTS	2015	1
58	KARTN	2015	1
59	KATMR	2015	1
60	KENT	2015	1
61	KLMSN	2015	1
62	KNFRT	2015	1
63	KONYA	2015	1
64	KORDS	2015	1
65	KUTPO	2015	1
66	LUKSK	2015	1
67	MRDIN	2015	1
68	NUHCM	2015	1
69	OLMIP	2015	1
70	OTKAR	2015	1

EK B. Başarısız Firmalar

No	Şirket	Başarısızlık Yılı (t)	t-1	t-2	t-3	Başarı Durumu
1	AEFES	2014	2013	2012	2011	0
2	AFYON	2011	2010	2009	2008	0
3	ALYAG	2014	2013	2012	2011	0
4	ASLAN	2009	2008	2007	2006	0
5	ATPET	2014	2013	2012	2011	0
6	AYES	2012	2011	2010	2009	0
7	BANVT	2013	2012	2011	2010	0
8	BFREN	2008	2007	2006	2005	0
9	BRMEN	2008	2007	2006	2005	0
10	CEMAS	2014	2013	2012	2011	0
11	CMBTN	2008	2007	2006	2005	0
12	DARDL	2010	2009	2008	2007	0
13	DENCM	2012	2011	2010	2009	0
14	DESA	2015	2014	2013	2012	0
15	DEVA	2008	2007	2006	2005	0
16	DGKLB	2014	2013	2012	2011	0
17	DGZTE	2008	2007	2006	2005	0
18	DIRIT	2013	2012	2011	2010	0
19	DITAS	2015	2014	2013	2012	0
20	DMISH	2010	2009	2008	2007	0
21	DURDO	2015	2014	2013	2012	0
22	EMKEL	2010	2009	2008	2007	0
23	EMNIS	2010	2009	2008	2007	0
24	EPLAS	2010	2009	2008	2007	0
25	GEREL	2010	2009	2008	2007	0
26	IHGZT	2015	2014	2013	2012	0
27	IZMDC	2013	2012	2011	2010	0
28	KAPLM	2013	2012	2011	2010	0
29	KERVT	2011	2010	2009	2008	0
30	KRDM	2015	2014	2013	2012	0
31	KRTEK	2012	2011	2010	2009	0
32	MAKTK	2011	2010	2009	2008	0
33	MEMSA	2011	2010	2009	2008	0
34	MERKO	2010	2009	2008	2007	0
35	MNDRS	2015	2014	2013	2012	0
36	MRSHL	2011	2010	2009	2008	0
37	NIBAS	2012	2011	2010	2009	0
38	OYLUM	2015	2014	2013	2012	0
39	OZBAL	2011	2010	2009	2008	0
40	PENGD	2013	2012	2011	2010	0
41	PIMAS	2013	2012	2011	2010	0
42	PINSU	2015	2014	2013	2012	0
43	PRKAB	2009	2008	2007	2006	0

EK B. Başarısız Firmalar (Devamı)

44	ROYAL	2016	2015	2014	2013	0
45	SAMAT	2013	2012	2011	2010	0
46	SANFM	2015	2014	2013	2012	0
47	SKTAS	2012	2011	2010	2009	0
48	TATGD	2012	2011	2010	2009	0
49	TRCAS	2014	2013	2012	2011	0
50	VANGD	2015	2014	2013	2012	0
51	VESTL	2011	2010	2009	2008	0
52	FENIS	2016	2015	2014	2013	0
53	MERT	2016	2015	2014	2013	0
54	PLASPAK	2016	2015	2014	2013	0
55	ÇBS	2014	2013	2012	2011	0
56	BSHEV	2014	2013	2012	2011	0
57	ECYAP	2015	2014	2013	2012	0
58	MUTLU	2015	2014	2013	2012	0
59	UYUM	2016	2015	2014	2013	0
60	GNPWR	2016	2015	2014	2013	0
61	ARBUL	2016	2015	2014	2013	0
62	TUMTK	2011	2010	2009	2008	0
63	LIOYS	2008	2007	2006	2005	0
64	MEGES	2008	2007	2006	2005	0
65	ABANA	2009	2008	2007	2006	0
66	ARTOG.E	2015	2014	2013	2012	0
67	DENTA	2014	2013	2012	2011	0
68	SKPLC	2015	2014	2013	2012	0
69	PRTAS	2014	2013	2012	2011	0
70	TUDDF	2015	2014	2013	2012	0