

**T.C.
ERCIYES ÜNİVERSİTESİ
SOSYAL BİLİMLER ENSTİTÜSÜ**

**FİNANSAL BAŞARISIZLIK TAHMİNİNDE GELENEKSEL
İSTATİSTİKİ YÖNTEMLERLE YAPAY SİNİR AĞLARININ
KARŞILAŞTIRILMASI VE SANAYİ İŞLETMELERİ
ÜZERİNDE UYGULAMA**

**Tezi Hazırlayan
Talip TORUN**

**Tezi Yöneten
Prof. Dr. İsmail Hakkı SÖNMEZ**

**İşletme Ana Bilim Dalı
Muhasebe – Finansman Bilim Dalı
Doktora Tezi**

**Aralık 2007
KAYSERİ**

**T.C.
ERCIYES ÜNİVERSİTESİ
SOSYAL BİLİMLER ENSTİTÜSÜ**

**FİNANSAL BAŞARISIZLIK TAHMİNİNDE
GELENEKSEL İSTATİSTİKİ YÖNTEMLERLE YAPAY
SİNİR AĞLARININ KARŞILAŞTIRILMASI VE SANAYİ
İŞLETMELERİ ÜZERİNDE UYGULAMA**

**Tezi Hazırlayan
Talip TORUN**

**Tezi Yöneten
Prof. Dr. İsmail Hakkı SÖNMEZ**

**İşletme Anabilim Dalı
Muhasebe-Finansman Bilim Dalı
Doktora Tezi**

**Aralık 2007
KAYSERİ**

Prof. Dr. İsmail Hakkı SÖNMEZ danışmanlığında **Talip TORUN** tarafından hazırlanan “**Finansal Başarısızlık Tahmininde Geleneksel İstatistikî Yöntemlerle Yapay Sinir Ağlarının Karşılaştırılması ve Sanayi İşletmeleri Üzerinde Uygulama**” adlı bu çalışma jürimiz tarafından Erciyes Üniversitesi Sosyal Bilimler Enstitüsü İşletme Anabilim Dalında **Doktora** tezi olarak kabul edilmiştir.

30.11.2007

JÜRİ:

Danışman :Prof. Dr. İsmail Hakkı SÖNMEZ

Üye :Prof. Dr. Metin Kamil ERCAN (Gazi Üniversitesi)

Üye :Yrd. Doç. Dr. Asım ÇELİK

Üye :Yrd. Doç. Dr. Levent ÇITAK

Üye :Yrd. Doç. Dr. Lale ÖZBAKIR

ONAY:

Bu tezin kabulü Enstitü Yönetim Kurulunun 07.12.2007 tarih ve 31 sayılı kararı ile onaylanmıştır.

07.12.2007

Prof.Dr. Kerim TÜRKMEN



ÖNSÖZ

Akademik hayatımın her aşamasında olduğu gibi, doktora tezimin hazırlanmasında da çok büyük destek aldığım Danışmanım Sn. Prof. Dr. İsmail Hakkı SÖNMEZ'e şükranlarımı sunarım. Tez çalışması boyunca yardımlarını esirgemeyen tez izleme komitesi hocalarım Sn. Prof. Dr. Metin Kamil ERCAN ve Sn. Yrd. Doç. Dr. Asım ÇELİK'e, çok değerli görüşleriyle çalışmaya önemli katkılarda bulunan tez savunma jürisi üyeleri Sn. Yrd. Doç. Dr. Levent ÇITAK ve Sn. Yrd. Doç. Dr. Lale ÖZBAKIR'a teşekkür ederim. Tez raporumun hazırlanması sırasında emeklerini esirgemedi yardımcı olan, Araş. Gör. Oğuzhan TÜRKER, Uzman Gökhan GÜVEN ve Uğur TÜRÜKLÜ'ye teşekkürlerimi sunarım.

Bugünlere gelmemi sağlayan anneme, babama ve abilerime emeklerinden dolayı minnettarım. Ayrıca, yoğun çalışmalarım esnasında kendilerini ciddi derecede ihmal ettiğimi düşündüğüm eşim Semra'ya ve çocuklarım Mehmet'le Fatih'e sabırlarından ve anlayışlarından dolayı içtenlikle teşekkür ederim.

Talip TORUN

FINANSAL BAŞARISIZLIK TAHMİNİNDE GELENEKSEL İSTATİSTİKİ YÖNTEMLERLE YAPAY SİNİR AĞLARININ KARŞILAŞTIRILMASI VE SANAYİ İŞLETMELERİ ÜZERİNDE UYGULAMA

Talip TORUN

ÖZET

Finansal başarısızlık, hem işletmeyle doğrudan ilgili gruplar üzerinde hem de genel ekonomi üzerinde olumsuz etkilere sahip olabilmektedir. Bu nedenle, finansal başarısızlığın tahmin edilmesi, finans alanında önemli araştırma konularından biri olmuştur. Uzun yıllar boyunca, farklı yöntemler kullanılarak finansal başarısızlığı tahmin edebilecek modeller geliştirilmeye çalışılmıştır. Bu yöntemler arasında, en yaygın olarak kullanılanları çok değişkenli istatistiki teknikler ve yapay sinir ağlarıdır.

Bu çalışmanın amacı, geleneksel istatistiki yöntemlerle yapay sinir ağlarının, Türkiye'deki sanayi işletmelerinin finansal durumunu tahmin etmedeki performanslarını karşılaştırarak, en uygun yöntemi belirlemektir.

Hisse senetleri İ.M.K.B.'de işlem gören sanayi işletmelerinin 1992-2004 yılları arası verileri üzerinde, geleneksel istatistiki teknikler (çok değişkenli diskriminant analizi ve lojistik regresyon analizi) ve yapay sinir ağları (geri yayımlı çok katmanlı yapay sinir ağı) kullanılarak tahmin modelleri geliştirilmiştir. Elde edilen modellerin beş yıl öncesine kadarki performansları, hem geleneksel performans ölçüleri, hem de ROC eğrileri aracılığıyla değerlendirilerek birbirleriyle karşılaştırılmıştır.

Başarısızlıktan bir ve iki yıl öncesi için en iyi performansa sahip yöntem yapay sinir ağıdır. İşletmeyle ilgili olarak verilecek çoğu karar için iki yıllık sürenin yeterli olduğu düşünüldüğünde, yapay sinir ağının finansal başarısızlık tahmininde kullanılmasının işletmeyle ilgili karar vericiler için son derece yararlı olacağı sonucuna varılmıştır. Ayrıca, başarısızlıktan beş yıl öncesine kadar tüm tahmin modellerinin ROC eğrisi altında kalan alanları 0,50'den daha büyüktür.

Anahtar Kelimeler: Finansal Başarısızlık, Çok Değişkenli Modeller, Yapay Sinir Ağları, ROC Eğrileri.

**COMPARISON OF TRADITIONAL STATISTICAL TECHNIQUES WITH
ARTIFICIAL NEURAL NETWORKS IN FINANCIAL FAILURE PREDICTION
AND AN APPLICATION ON INDUSTRY FIRMS**

Talip TORUN

ABSTRACT

Financial failure may negatively affect both stakeholders and overall economy. Therefore, predicting financial failure has become an important subject in financial research area. For many years researchers have tried to develop models that predict financial failure using different methods. Among these methods, multivariate statistical methods and artificial neural networks are used most widely.

The objective of this study is to determine the most appropriate method by comparing the performances of traditional statistical methods and artificial neural networks in predicting financial positions of industry firms in our country.

In this study, prediction models have been built by means of traditional statistical methods(multivariate discriminant analysis and logistic regression analysis) and artificial neural networks (multilayer neural networks with backpropagation algorithm) using data of industry firms whose stocks were traded in Istanbul Stock Exchange (ISE) between years 1992 and 2004. Performances of models developed for five year period are compared by using both traditional performance measures and ROC curves.

In predicting failure one and two years earlier, artificial neural network has the best performance. Considering that two years is enough for most of the decisions about the firm, it has been concluded that using artificial neural networks in predicting financial failure will be very beneficial for decision makers. Besides, for up to five years prior to failure, the area under the ROC curve in all prediction models is more than 0,50.

Key Words: Financial Failure, Multivariate Models, Artificial Neural Networks, ROC Curves.

İÇİNDEKİLER

ÖNSÖZ	i
ÖZET	ii
ABSTRACT	iii
KISALTMALAR LİSTESİ	viii
TABLolar LİSTESİ	ix
ŞEKİLLER LİSTESİ	xi
GİRİŞ	1
BİRİNCİ BÖLÜM: FİNANSAL BAŞARISIZLIK VE FİNANSAL BAŞARISIZLIK TAHMİNİ	5
1.1. FİNANSAL BAŞARISIZLIK.....	5
1.1.1. Finansal Başarısızlığın Tanımı	5
1.1.2. Finansal Başarısızlığın Nedenleri	8
1.1.2.1. İşletme Dışı Nedenler	9
1.1.2.2. İşletme İçi Nedenler	11
1.1.3. Finansal Başarısızlığı Önleme Yolları	13
1.2. FİNANSAL BAŞARISIZLIK TAHMİNİ	14
1.2.1. Finansal Başarısızlığın Tahmin Edilmesinin Önemi	14
1.2.2. Finansal Başarısızlık Tahmin Modellerinin Gelişimine Katkıda Bulunan Faktörler.....	19
1.2.3. Finansal Başarısızlık Tahmin Çalışmaları.....	20
İKİNCİ BÖLÜM: FİNANSAL BAŞARISIZLIK TAHMİNİNDE KULLANILAN YÖNTEMLER VE METODOLOJİK SORUNLAR	31
2.1. FİNANSAL BAŞARISIZLIK TAHMİNİNDE KULLANILAN YÖNTEMLER	31
2.1.1. Teorik Modeller	31
2.1.1.1. Bilanço Bozulma Ölçüsü/Entropi Teorisi	32
2.1.1.2. Kumarbazın İflası Teorisi.....	32
2.1.1.3. Nakit Yönetimi Teorisi.....	33
2.1.1.4. Felaket Teorisi ve Kaos Teorisi	33
2.1.2. İstatistikî ve Matematiksel Modeller	33
2.1.2.1. Tek Değişkenli Analiz.....	34

2.1.2.2. Risk İndeksi Modelleri	36
2.1.2.3. Çok Değişkenli Diskriminant Analizi	36
2.1.2.4. Koşullu Olasılık Modelleri	40
2.1.2.4.1. Doğrusal Olasılık Modeli.....	41
2.1.2.4.2. Lojistik Regresyon Analizi	42
2.1.2.4.3. Probit Modeli	46
2.1.3. Yapay Zeka Modelleri.....	46
2.1.3.1. Yapay Sinir Ağı Yaklaşımı.....	47
2.1.3.2. Yapay Sinir Ağlarının Avantajları	52
2.1.3.3. Yapay Sinir Ağlarının Dezavantajları	53
2.1.3.3.1. Aşırı Uygunluk (Aşırı Öğrenme) Problemi	55
2.1.3.3.2. Yerel Minimum Problemi	55
2.1.3.4. Yapay Sinir Ağı Türleri.....	56
2.1.3.5. Çok Katmanlı Perseptronlar ve Geri Yayılım Algoritması	57
2.1.3.6. Yapay Sinir Ağının Modellenmesi	59
2.1.3.7. Yapay Sinir Ağı ve İstatistiksel Yöntemler	62
2.1.3.8. Yapay Sinir Ağı Terminolojisi ve İstatistiksel Terminoloji	64
2.2. FİNANSAL BAŞARISIZLIK TAHMİN ÇALIŞMALARINDA KARŞILAŞILAN METODOLOJİK SORUNLAR	65
2.2.1. Örneklemeye Yöntemiyle İlgili Problemler.....	65
2.2.2. İkili Bağımlı Değişken Varsayımıyla İlgili Problemler	69
2.2.3. Bağımsız Değişkenlerin Seçimiyle İlgili Problemler	72
2.2.4. Finansal Oranların Kullanımıyla İlgili Problemler	75
2.2.5. Durağan Olmama ve Veri İstikrarsızlığıyla İlgili Problemler	80
2.2.6. Hata Maliyetlerinin Etkisi	83
ÜÇÜNCÜ BÖLÜM: GELENEKSEL İSTATİSTİKİ YÖNTEMLER VE YAPAY SİNİR AĞLARIYLA SANAYİ İŞLETMELERİNDE FİNANSAL BAŞARISIZLIĞIN TAHMİN EDİLMESİ	85
3.1. UYGULAMANIN AMACI	85
3.2. UYGULAMADA KULLANILAN YÖNTEMLER VE YAZILIMLAR	85
3.3. UYGULAMA ÖRNEĞİ	86
3.4. BAĞIMSIZ DEĞİŞKENLERİN SEÇİMİ	89
3.5. FİNANSAL BAŞARISIZLIK TAHMİNİ İÇİN KURULAN MODELLER.....	91

3.5.1. Diskriminant Modeli	92
3.5.2. Lojistik Regresyon Modeli	93
3.5.3. Yapay Sinir Ağı Modeli	94
3.6. GELENEKSEL PERFORMANS ÖLÇÜLERİ YARDIMIYLA TAHMİN MODELLERİNİN PERFORMANSLARININ DEĞERLENDİRİLMESİ.....	96
3.6.1. Geleneksel Performans Ölçüleri	96
3.6.2. Tahmin Modellerinin Performansları	97
3.6.2.1. Başarısızlıktan Bir Yıl Öncesi için Tahmin Modellerinin Performansları	98
3.6.2.2. Başarısızlıktan İki Yıl Öncesi için Tahmin Modellerinin Performansları	102
3.6.2.3. Başarısızlıktan Üç Yıl Öncesi için Tahmin Modellerinin Performansları	105
3.6.2.4. Başarısızlıktan Dört Yıl Öncesi için Tahmin Modellerinin Performansları	108
3.6.2.5. Başarısızlıktan Beş Yıl Öncesi için Tahmin Modellerinin Performansları	111
3.6.2.6. Tüm Yıllar için Tahmin Modellerinin Performansları.....	113
3.7. ROC EĞRİLERİ YARDIMIYLA TAHMİN MODELLERİNİN PERFORMANSLARININ DEĞERLENDİRİLMESİ	114
3.7.1. ROC Eğrileri (Receiver Operating Characteristic Curves)	114
3.7.2. Başarısızlıktan Bir Yıl Öncesi için ROC Eğrileri Kullanılarak Modellerin Karşılaştırılması.....	116
3.7.3. Başarısızlıktan İki Yıl Öncesi için ROC Eğrileri Kullanılarak Modellerin Karşılaştırılması.....	119
3.7.4. Başarısızlıktan Üç Yıl Öncesi için ROC Eğrileri Kullanılarak Modellerin Karşılaştırılması.....	123
3.7.5. Başarısızlıktan Dört Yıl Öncesi için ROC Eğrileri Kullanılarak Modellerin Karşılaştırılması.....	125
3.7.6. Başarısızlıktan Beş Yıl Öncesi için ROC Eğrileri Kullanılarak Modellerin Karşılaştırılması.....	128
3.7.7. Tüm Yıllar için ROC Eğrileri Altında Kalan Alanlar.....	131
SONUÇ	134

KAYNAKÇA	138
EKLER	153
EK-1 Uygulama için Örnek Setlerini Oluşturan İşletmeler.....	154
EK-2 Bağımsız Değişken Olarak Kullanılan Finansal Oranların Formülleri.....	158
EK-3 Diskriminant Analizi Çıktıları.....	159
EK-4 Lojistik Regresyon Analizi Çıktıları.....	161
EK-5 Başarısızlıktan 1 Yıl Öncesi için Diskriminant Analizi, Lojistik Regresyon ve Yapay Sinir Ağları Modellerinin Sonuçları ve Tahminleri.....	163
EK-6 Başarısızlıktan 2 Yıl Öncesi için Diskriminant Analizi, Lojistik Regresyon ve Yapay Sinir Ağları Modellerinin Sonuçları ve Tahminleri.....	166
EK-7 Başarısızlıktan 3 Yıl Öncesi için Diskriminant Analizi, Lojistik Regresyon ve Yapay Sinir Ağları Modellerinin Sonuçları ve Tahminleri.....	169
EK-8 Başarısızlıktan 4 Yıl Öncesi için Diskriminant Analizi, Lojistik Regresyon ve Yapay Sinir Ağları Modellerinin Sonuçları ve Tahminleri.....	172
EK-9 Başarısızlıktan 5 Yıl Öncesi için Diskriminant Analizi, Lojistik Regresyon ve Yapay Sinir Ağları Modellerinin Sonuçları ve Tahminleri.....	175
ÖZGEÇMİŞ	178

KISALTMALAR LİSTESİ

DA	Diskriminant Analizi
İ.M.K.B.	İstanbul Menkul Kıymetler Borsası
LR	Lojistik Regresyon
ROC Curve	Alıcı İşletim Karakteristik Eğrisi (Receiver Operating Characteristic Curve)
S.P.K.	Sermaye Piyasası Kurulu
SEC	ABD Menkul Kıymetler ve Borsa Komisyonu (Securities and Exchange Commission)
SOM	Özörgütlemeli Haritalar (Self Organizing Maps)
T.C.M.B.	Türkiye Cumhuriyeti Merkez Bankası
U.F.R.S.	Uluslararası Finansal Raporlama Standartları
YSA	Yapay Sinir Ağı

TABLOLAR LİSTESİ

Tablo 1.1. Problemlı İşletmelerin Özellikleri	8
Tablo 2.1. İstatistiksel Terminoloji ve Yapay Sinir Ağı Terminolojisi Arasındaki Farklar	65
Tablo 3.1. En İyi Performansa Sahip Yapay Sinir Ağıın Özellikleri.....	95
Tablo 3.2. Genel Sınıflandırma Matrisi.....	96
Tablo 3.3. Kestirim/Eğitim Seti için Sınıflandırma Matrisi (t-1 Dönemi)	99
Tablo 3.4. Kontrol/Test Seti için Sınıflandırma Matrisi (t-1 Dönemi)	100
Tablo 3.5. Kestirim/Eğitim Seti için Sınıflandırma Matrisi (t-2 Dönemi)	102
Tablo 3.6. Kontrol/Test Seti için Sınıflandırma Matrisi (t-2 Dönemi)	103
Tablo 3.7. Kestirim/Eğitim Seti için Sınıflandırma Matrisi (t-3 Dönemi)	105
Tablo 3.8. Kontrol/Test Seti için Sınıflandırma Matrisi (t-3 Dönemi)	106
Tablo 3.9. Kestirim/Eğitim Seti için Sınıflandırma Matrisi (t-4 Dönemi)	108
Tablo 3.10. Kontrol/Test Seti için Sınıflandırma Matrisi (t-4 Dönemi)	109
Tablo 3.11. Kestirim/Eğitim Seti için Sınıflandırma Matrisi (t-5 Dönemi)	111
Tablo 3.12. Kontrol/Test Seti için Sınıflandırma Matrisi (t-5 Dönemi)	112
Tablo 3.13. Her Üç Modelin Tüm Dönemlere İlişkin Performans Ölçüleri.....	113
Tablo 3.14. Kestirim/Eğitim Seti ROC Eğrileri Altında Kalan Alanlar (t-1 Dönemi) .	117
Tablo 3.15. Kestirim/Eğitim Seti ROC Eğrileri Altında Kalan Alanlar için İkili Karşılaştırma Sonuçları (t-1 Dönemi)	118
Tablo 3.16. Kontrol/Test Seti ROC Eğrileri Altında Kalan Alanlar (t-1 Dönemi).....	119
Tablo 3.17. Kontrol/Test Seti ROC Eğrileri Altında Kalan Alanlar için İkili Karşılaştırma Sonuçları (t-1 Dönemi)	119
Tablo 3.18. Kestirim/Eğitim Seti ROC Eğrileri Altında Kalan Alanlar (t-2 Dönemi) .	120
Tablo 3.19. Kestirim/Eğitim Seti ROC Eğrileri Altında Kalan Alanlar için İkili Karşılaştırma Sonuçları (t-2 Dönemi)	121
Tablo 3.20. Kontrol/Test Seti ROC Eğrileri Altında Kalan Alanlar (t-2 Dönemi).....	122
Tablo 3.21. Kontrol/Test Seti ROC Eğrileri Altında Kalan Alanlar için İkili Karşılaştırma Sonuçları (t-2 Dönemi)	122
Tablo 3.22. Kestirim/Eğitim Seti ROC Eğrileri Altında Kalan Alanlar (t-3 Dönemi) .	123
Tablo 3.23. Kestirim/Eğitim Seti ROC Eğrileri Altında Kalan Alanlar için İkili Karşılaştırma Sonuçları (t-3 Dönemi)	124

Tablo 3.24. Kontrol/Test Seti ROC Eğrileri Altında Kalan Alanlar (t-3 Dönemi).....	125
Tablo 3.25. Kontrol/Test Seti ROC Eğrileri Altında Kalan Alanlar için İkili Karşılaştırma Sonuçları (t-3 Dönemi)	125
Tablo 3.26. Kestirim/Eğitim Seti ROC Eğrileri Altında Kalan Alanlar (t-4 Dönemi) .	126
Tablo 3.27. Kestirim/Eğitim Seti ROC Eğrileri Altında Kalan Alanlar için İkili Karşılaştırma Sonuçları (t-4 Dönemi)	127
Tablo 3.28. Kontrol/Test Seti ROC Eğrileri Altında Kalan Alanlar (t-4 Dönemi).....	128
Tablo 3.29. Kontrol/Test Seti ROC Eğrileri Altında Kalan Alanlar için İkili Karşılaştırma Sonuçları (t-4 Dönemi)	128
Tablo 3.30. Kestirim/Eğitim Seti ROC Eğrileri Altında Kalan Alanlar (t-5 Dönemi) .	129
Tablo 3.31. Kestirim/Eğitim Seti ROC Eğrileri Altında Kalan Alanlar için İkili Karşılaştırma Sonuçları (t-5 Dönemi)	130
Tablo 3.32. Kontrol/Test Seti ROC Eğrileri Altında Kalan Alanlar (t-5 Dönemi).....	131
Tablo 3.33. Kontrol/Test Seti ROC Eğrileri Altında Kalan Alanlar için İkili Karşılaştırma Sonuçları (t-5 Dönemi)	131
Tablo 3.34. Her Üç Modelin Tüm Dönemlere İlişkin ROC Eğrisi Altında Kalan Alanları	132

ŞEKİLLER LİSTESİ

Şekil 2.1. Sinir Hücresinin Yapısı.....	50
Şekil 2.2. Aktivasyon Fonksiyonları.....	51
Şekil 2.3. Çok Katmanlı Perseptron.....	58
Şekil 2.4. Doğrusal Diskriminant Analizine Eşdeğer Perseptron.....	63
Şekil 2.5. Lojistik Regresyon Analizine Eşdeğer Perseptron.....	64
Şekil 3.1. En İyi Performansa Sahip Yapay Sinir Ağının Mimarisi	95
Şekil 3.2. İdeal ve Kötü Performans Göstergesi Olan ROC Eğrileri.....	116
Şekil 3.3. Kestirim/Eğitim Seti ROC Eğrileri (t-1 Dönemi)	117
Şekil 3.4. Kontrol/Test Seti ROC Eğrileri (t-1 Dönemi).....	118
Şekil 3.5. Kestirim/Eğitim Seti ROC Eğrileri (t-2 Dönemi)	120
Şekil 3.6. Kontrol/Test Seti ROC Eğrileri (t-2 Dönemi).....	121
Şekil 3.7. Kestirim/Eğitim Seti ROC Eğrileri (t-3 Dönemi)	123
Şekil 3.8. Kontrol/Test Seti ROC Eğrileri (t-3 Dönemi).....	124
Şekil 3.9. Kestirim/Eğitim Seti ROC Eğrileri (t-4 Dönemi)	126
Şekil 3.10. Kontrol/Test Seti ROC Eğrileri (t-4 Dönemi).....	127
Şekil 3.11. Kestirim/Eğitim Seti ROC Eğrileri (t-5 Dönemi)	129
Şekil 3.12. Kontrol/Test Seti ROC Eğrileri (t-5 Dönemi).....	130

GİRİŞ

İşletme başarısızlığı yatırımcılar, kredi verenler, yöneticiler gibi işletmeyle doğrudan ilgili gruplara önemli maliyetler yüklemektedir. İşletme başarısızlıklarının olumsuz etkisi, sadece bu gruplar üzerinde sınırlı değildir. Başarısız işletmelerin sayısının artması, yayılma etkisiyle tüm ekonomi üzerinde istihdam ve ekonomik refahla ilgili olumsuz sonuçlara neden olabilmektedir. Bu bakış açısı altında işletme başarısızlığı, sadece bireysel etkileri olan bir kavram değil, aynı zamanda tüm toplumu etkileyebilen sosyal bir kavramdır.

Bir işletmenin finansal durumunu önceden tahmin edebilecek bir model, işletme ile ilgili kararlar almada çeşitli çevrelere çok büyük fayda sağlayacaktır. Böyle bir model, yatırımcılar tarafından yeni bir yatırım kararı vermede ya da mevcut yatırımların izlenmesinde kullanılabileceği gibi, kredi verenler tarafından potansiyel müşterilerini ya da mevcut müşterilerini değerlendirmede önemli bir araç olacaktır. Ayrıca, yöneticiler böyle bir model sayesinde, başarısızlığa karşı önleyici tedbirler alma fırsatı yakalayacaklardır.

Finansal başarısızlık tahmini, finans alanında önemli araştırma konularından biri olmuştur. Yıllar boyunca, farklı yöntemler kullanarak tahmin modelleri geliştirmeye çalışan çok sayıda araştırma yapılmıştır. Başarısızlık tahmin modeli kurmada kullanılan tüm teknik ve yöntemlerin kendine özgü avantajları ve dezavantajları bulunduğundan, her koşul ve ortamda geçerli mükemmel bir model ya da yöntem bulunmamaktadır. Söz konusu eksiklik, bu alandaki çalışmaların günümüzde de devam etmesindeki en büyük etkendir.

Finansal başarısızlık tahmin alanında, istatistiki teknikler yıllarca başarıyla kullanılmıştır. Teknolojinin hızla gelişmesiyle birlikte, insan beynini taklit eden sistemler kurmaya yönelik çalışmalar, yapay sinir ağlarının ortaya çıkmasına ve gelişmesine neden olmuştur. Günümüzde yapay sinir ağları, farklı araştırma

alanlarındaki problemleri çözmeye yaygın olarak kullanılmaktadır. Bu bağlamda, yapay sinir ağları istatistiki ve matematiksel yöntemlere yardımcı olma veya onlara alternatif oluşturma eğilimindedir. Yapılan çalışmalarda kanıtlar, istatistiki tekniklerin yetersiz kaldığı ya da iyi sonuçlar vermediği alanlarda, yapay sinir ağlarının karmaşık ilişkileri yakalayabildiği yönündedir. Üstelik, yapay sinir ağları, bazı istatistiki tekniklerin ihtiyaç duyduğu, fakat gerçek veriler için sağlanması zor bazı sınırlayıcı varsayımları da gerektirmemektedir. Bu durum, aralarında finansal başarısızlık tahmininin de bulunduğu çeşitli finans alanlarında, yapay sinir ağlarının uygulanmasının önem kazanmasına ve yaygınlaşmasına neden olmuştur.

Bu çalışmanın amacı; Türkiye'deki sanayi işletmelerinin başarısızlıklarını tahmin etmede geleneksel istatistiki yöntemlerle yapay sinir ağlarını karşılaştırarak, en uygun yöntemi belirlemektir.

Bu çalışmada, geleneksel istatistiki yöntemleri temsilen daha önceki çalışmalar tarafından başarısızlık tahminleri için uygun oldukları kanıtlanan çok değişkenli diskriminant analizi ve lojistik regresyon analizi seçilmiştir. Söz konusu istatistiki teknikler, çeşitli bağımsız değişkenler yardımıyla işletmeleri önceden bilinen gruplara sınıflandırmaya çalışmaktadırlar. Yapay sinir ağlarında denetimli ve denetimsiz olmak üzere iki öğrenme türü bulunmaktadır. Diskriminant analize ve lojistik regresyon analizine benzer şekilde, denetimli öğrenmede bağımsız (girdi) ve bağımlı değişkenler (çıkıtı) kullanılarak yapay sinir ağı eğitilmektedir. Bunun için, bu çalışmada denetimli öğrenme kapsamında yer alan geri yayımlı çok katmanlı yapay sinir ağı tercih edilmiştir. Bu ağı tercih edilmesindeki diğer bir neden de, literatürde sınıflandırma problemleri için en uygun yapay sinir ağı türü olarak gösterilmesidir.

Hisse senetleri İ.M.K.B.'de işlem gören 45 başarısız ve 45 başarılı olmak üzere 90 sanayi işletmesi üzerinde, diskriminant analizi, lojistik regresyon analizi ve yapay sinir ağı yöntemleri kullanılarak tahmin modelleri geliştirilmiştir. Çalışmada, sanayi işletmelerinin 1992-2004 yılları arası verileri kullanılmıştır. Elde edilen modellerin beş yıl öncesine kadar olan performansları, hem modelin üzerinde kurulduğu kestirim seti üzerinde, hem de test seti üzerinde değerlendirilmiştir.

Finansal başarısızlık tahmini için geliştirilen farklı modellerin karşılaştırıldığı çalışmaların neredeyse tamamında, performans ölçüsü olarak "başarısız işletmeleri

sınıflandırma doğruluğu”, “başarılı işletmeleri sınıflandırma doğruluğu” ve “toplam sınıflandırma doğruluğu” kullanılmıştır. Bu geleneksel performans ölçüleri, finansal başarısızlık tahmini için yanıtıcı sonuçlara neden olabilmektedir. Çünkü, söz konusu performans ölçülerinde 1. tip hata ve 2. tip hata maliyetlerinin eşit olduğu varsayılmaktadır. Oysa başarısız işletmelerin başarılı olarak tahmin edilmesi anlamına gelen 1. tip hata maliyetinin, diğer hata maliyetine göre çok daha fazla olduğu bilinen bir gerçektir. Üstelik, bu performans ölçüleri sadece önceden belirlenmiş tek bir kopuş değeri için geçerlidir. Bu alanda yapılan ve yapılacak olan çalışmalarla karşılaştırılabilir olması açısından, bu çalışmada söz konusu performans ölçüleri kullanılmasına rağmen, geleneksel ölçülerin eksikliklerini ortadan kaldıran ROC eğrileri de kullanılmıştır. Söz konusu özelliğiyle bu çalışma, finansal başarısızlık tahmin literatüründe geleneksel ölçülerin dışında farklı performans ölçüleri kullanan çok az sayıda çalışmadan biri, Türkiye’deki ise ilk çalışmadır.

Başarısızlıktan önceki farklı yıllar için tahmin modelleri geliştirmede, üç farklı yol izlenebilmektedir. Birincisi, her yıl için farklı değişkenlere ve farklı katsayılara sahip modeller kurma, ikincisi her yıl için aynı değişkenlere sahip fakat farklı katsayıları bulunan modeller kurma ve üçüncüsü ise tüm yıllar için aynı değişkenlere ve aynı katsayılara sahip tek bir model kurmadır. İlk iki yöntem, başarısızlıktan önceki yıllar için değişkenlerin önemini araştırmada faydalı olmakla birlikte, tahmin bağlamında en uygun yol üçüncüsüdür. Amacına uygun olarak bu çalışmada üçüncü yol izlenmiştir. Yani her bir yöntem için tek bir model geliştirilerek, başarısızlıktan beş yıl öncesine kadar bu modellerin performansları değerlendirilmiş ve karşılaştırılmıştır. Gerek farklı yıllar için tek bir model kullanılması, gerekse tahmin sonuçlarının başarısızlıktan beş yıl öncesine kadar incelenmesi yönünden Türkiye’de yapılmış ilk çalışmadır. Modellerin tahmin yetenekleri beş yıl öncesine kadar değerlendirilerek, sadece kısa vadeli kararlar için değil uzun vadeli stratejik bazı kararlar için de finansal başarısızlık tahmin modellerinin uygun araçlar olup olmadığı değerlendirilmiştir.

Çalışma üç bölümden oluşmaktadır. Birinci bölümde finansal başarısızlığın tanımı, nedenleri ve alınabilecek önlemler ortaya konulduktan sonra finansal başarısızlığın tahmin edilmesinin önemi ve bu alanda yapılan çalışmalar anlatılmaktadır.

İkinci bölümde ise finansal başarısızlığın tahmin edilmesinde kullanılan yöntemler genel hatlarıyla tanıtılarak, finansal başarısızlık tahmin modelleri geliştirmede yaygın olarak karşılaşılan sorunlar ele alınmaktadır.

Uygulamanın yer aldığı üçüncü bölümde ise uygulamayla ilgili temel bilgiler sunulduktan sonra diskriminant analizi, lojistik regresyon analizi ve yapay sinir ağları ile oluşturulan modeller ve başarısızlıktan beş yıl öncesine kadar bu modellerin performans karşılaştırmaları yer almaktadır.

BİRİNCİ BÖLÜM: FİNANSAL BAŞARISIZLIK VE FİNANSAL BAŞARISIZLIK TAHMİNİ

1.1. FİNANSAL BAŞARISIZLIK

1.1.1. Finansal Başarısızlığın Tanımı

İşletmelerin finansal başarısızlıklarının erken uyarı sinyallerini tanımlamak ve nedenlerini belirlemek için çok sayıda çalışma yapıldığı bilinen bir gerçektir. Buna rağmen finansal başarısızlığın genel kabul görmüş tek bir tanımı bulunmamaktadır. Yapılan çalışmalarda finansal başarısızlık tanımları, belirli bir risk düzeyinde yatırılan sermayeden beklenen getirinin elde edilememesinden, işletmenin varlıklarının tasfiye edilmesiyle sonuçlanan iflasa kadar uzanmaktadır.

Sözlüklerde genel olarak başarısızlık terimi, “eksik olmak, yetersiz olmak”, finansal başarısızlık ise “iflas etme, acze düşme” olarak tanımlanmaktadır¹.

Finans literatüründe yaygın olarak kullanılan finansal başarısızlık türleri ve bunların tanımları aşağıda yer almaktadır²:

Ekonomik Başarısızlık: Ekonomik açıdan başarısızlık; bir işletmenin gelirlerinin, sermaye maliyetini de içeren toplam maliyetlerini karşılayamamasını ifade etmektedir. Ekonomik açıdan başarısız olan işletmeler, ancak yatırımcıların ilave sermaye sağlamaya istekli olmaları durumunda veya işletme sahiplerinin piyasanın altında getiri oranlarını kabul etmeye razı olmaları halinde faaliyetlerini sürdürebilmektedir. Fakat,

¹ Karl Gratzler; “Business Failure and the New Economy”, EBHA Conference 2001: Business and Knowledge, July 2001, p.2-3.

² Eugene F. Brigham; Louis C. Gapenski; Financial Management: Theory and Practice, Seventh Edition, The Dryden Press, 1994, p.1015.

eninde sonunda ilave sermaye sağlanamaz hale gelir ve işletme varlıkları tükenir. Bu durumdaki işletmeler ya kapanır ya da normal bir getirinin sağlanacağı daha küçük bir işletmeye dönüşürler.

İşletme Başarısızlığı: İşletme başarısızlığı terimi, dünyanın en güvenilir uluslararası derecelendirme kuruluşlarından biri olan Dun&Bradstreet tarafından “bir işletmenin kredi verenlerin zarar etmelerine neden olacak şekilde faaliyetlerini durdurması” olarak tanımlanmaktadır. Böylece bir işletme, yasal iflas sürecine girmese bile başarısız olarak değerlendirilebilir. Bu tanıma göre, borç verenleri zarara uğratmadıkça bir işletmenin faaliyetlerini durdurması veya kapanması işletme başarısızlığı olarak görülmemektedir.

Teknik Acizlik: Bir işletme, vadesi geldiğinde cari yükümlülüklerini karşılayamıyorsa teknik olarak borçlarını ödeyemez (aciz) sayılır. Teknik acizlik, belirli bir zamandaki geçici likidite noksanlığını gösterebilir. Dolayısıyla teknik olarak aciz olan bir işletme nakit sıkıntısı sorununu çözebilir, yükümlülüklerini tamamıyla yerine getirebilir ve faaliyetlerini sürdürebilir. Diğer taraftan, teknik acizlik ekonomik başarısızlığın belirtisi olarak ortaya çıktığında, işletme için ciddi sorunlara neden olabilmektedir.

Negatif Net Değere Sahip Olma: Toplam yükümlülüklerinin defter değeri, varlıklarının gerçek değerinden daha fazla olan işletme negatif net değere sahiptir. Bu, teknik acizlikten daha önemli bir durumdur. Çünkü, negatif net değere sahip olma genellikle ekonomik başarısızlığın bir işaretidir ve sıklıkla işletmenin tasfiyesiyle sonuçlanır. Ancak, negatif net değere sahip olan işletmelerin, kimi zaman yasal iflas sürecine girmeyeceğini burada belirtmek gerekmektedir.

İflas: İflas terimi, hukuki bir özellik taşımaktadır. Bazen, başarısız bir işletmeyi belirtmek için kullanılmasına rağmen, mahkeme tarafından ilan edilmedikçe hiç bir işletme hukuki olarak iflas etmiş sayılmaz.

Neoklasik ekonomistler, başarısızlığı işletmenin piyasadan çıkışıyla eşdeğer görmektedirler. Bu açıdan başarısızlık, piyasanın etkin ve etkin olmayan işletmeler arasında yaptığı seçimin bir göstergesidir. Neoklasik görüşü savunanlara göre, işletmenin piyasada etkinliğini azaltan ve sektörden çıkmasına neden olan temel faktör, yetersiz kârlılıktır. Rekabetçi fiyat-maliyet marjlarında faaliyet gösteremeyen işletmeler, finansal güçlüklerle karşılaşmaktadırlar. Bu temelde, işletmenin piyasadan olası çıkışı

refah artırıcı bir araç ve sektöre özgü kaynakların yeniden dağılımının bir yolu olarak görülebilir. Ancak, bir işletme birleşme sonucunda da piyasadan çıkabilir. Rakipler başarılı bir işletmenin varlıklarını ve uzmanlığını ele geçirebilir. Bu durumda piyasadan çıkışın başarısızlıktan değil başarıdan kaynaklandığına dikkat edilmelidir³.

Literatürde yer alan ampirik çalışmaların bazılarında iflas, bazılarında ise finansal başarısızlık terimi kullanılmıştır. Finansal başarısızlık teriminin kullanılması, araştırmanın yürütülmesinde bazı kolaylıklar sağlamaktadır. Finansal başarısızlık, iflasa kıyasla daha esnek bir tanım olduğundan, araştırma örneğinin daha geniş tutulmasına imkan sağlamaktadır. Çünkü iflas, finansal başarısızlığın özel bir halidir. Çalışmalarda iflas kriterinin esas alınması genellikle örnek işletme sayısını azaltmaktadır. Finansal başarısızlık teriminin kullanılması, uygulamadaki bu üstünlüğünün yanında kuramsal açıdan da üstünlük taşımaktadır. Çünkü, finansal sorunları olan her işletme iflas etmemektedir. İflas, finansal sorunlarını çözemeyen işletmeler için son çare olarak başvurulmuş bir yoldur. Dolayısıyla, çalışmalarda iflas teriminin kullanılması, finansal başarısızlığın dar kapsamda ele alınmasına neden olabilmektedir⁴.

Karels ve Prakash (1987), finansal başarısızlığın tahmini ile ilgili ampirik çalışmalarda, araştırmacılar tarafından kullanılan çeşitli finansal başarısızlık tanımlarını kapsayan bir tablo sunmuşlardır. Finansal bir bakış açısıyla hazırlanan bu tablodaki başarısızlık tanımları; negatif net değeri, borçları ödeyememe durumunu (acizlik), tahvil anapara ve faizlerini ödemedede temerrüde düşmeyi, karşılıksız çek verilmesini, imtiyazlı hisse senetlerine temettülerin ödenmemesini, yönetimin alacaklıların kontrolü altına geçmesini vb. kapsamaktadır⁵. Benzer şekilde, Lin ve McClean, ampirik çalışmalarda yaygın olarak başvurulmuş işletme başarısızlığı ve finansal sıkıntı tanımlarını sunmuştur. Bu tanımlar Tablo 1.1. de yer almaktadır.

³ John Hunter; Natalia Isachenkova; "Aggregate Economy Risk and Company Failure: An Examination of UK Quoted Firms in the Early 1990s", BAA 2003 Annual Conference, Manchester, April 2004, p.3.

⁴ Ramazan Aktaş; Endüstri İşletmeleri İçin Mali Başarısızlık Tahmini (Çok Boyutlu Model Uygulaması), Türkiye İş Bankası Kültür Yayınları, Yayın No: 323, Ankara, 1993, s.5.

⁵ Gordon V. Karels; Arun J. Prakash; "Multivariate Normality and Forecasting of Business Bankruptcy", Journal of Business Finance & Accounting, Vol. 14, No. 4, 1987, pp.573-593.

Tablo 1.1. Problemlı İşletmelerin Özellikleri

1) Alacaklıların Yönetimi Altına Girme	7) Negatif Nakit Akışı
2) Yeniden Organizasyon Sürecine Girme	8) Negatif İşletme Sermayesi
3) Faiz Ödemelerini Karşılایamama	9) Üç Yıl Üst Üste Zarar
4) Olumsuz Denetçi Raporu	10) İki Yıl Üst Üste Zarar
5) Tasfiye Sürecine Girme	11) Cari Yıl Zarar
6) Negatif Net Değer	12) Esas Faaliyetlerden Zarar

Kaynak: Feng Yu Lin, Sally McClean, “The Prediction of Financial Distress Using a Cost Sensitive Approach and Prior Probabilities”, 17th International Conference on Machine Learning Workshop on Cost Sensitive Learning, Stanford University, USA, 2000, p.2.

Finansal başarısızlığın farklı tanımları, bu alanda yapılan çalışmaları doğrudan etkilemektedir. Böyle bir çalışmada kullanılacak veri seti, finansal başarısızlık tanımına göre belirlenmektedir. Dolayısıyla, farklı tanımlar farklı veri setlerinin kullanılmasına yol açmaktadır. Bu çalışmada finansal başarısızlık kriteri olarak, işletmenin iki yıl üst üste zarar etmesi, borsada tahtasının kapanması, faaliyetlerinin durması ve iflas esas alınmıştır.

1.1.2. Finansal Başarısızlığın Nedenleri

Herhangi bir işletmenin başarısı ya da başarısızlığı, iki temel faktör kümesinin etkileşiminin bir sonucudur. İlk olarak, bir işletmenin performansı işletme dışı faktörler tarafından etkilenir ve bu faktörler işletme yöneticilerinin kontrolü dışındadır. Ekonominin büyüme oranı, enflasyon, döviz kuru, faiz oranı, tercihlerin, tutumların ve tüketici davranışlarının değişmesi, pazardaki faaliyet karakteristiklerinin değişmesi gibi çevresel koşullar açık bir şekilde işletmenin pazar gücünü ve kârlılığını etkiler⁶.

⁶ Subhash Sharma; Vijay Mahajan; “Early Warning Indicators of Business Failure”, Journal of Marketing, Vol. 44, Fall 1980, pp.80-89, p.82.

Bir işletmenin performansını etkileyen diğer temel faktörler ise işletmenin kendi içerisinde ortaya çıkan ve kontrol edilmesi mümkün görülen faktörlerdir.

Uluslararası derecelendirme kuruluşu Dun&Bradstreet tarafından, 1987 yılında yürütülen çalışmaya göre, işletme başarısızlıkları aşağıdaki beş temel faktörden kaynaklanmaktadır⁷:

- Ekonomik faktörler,
- Yönetimin tecrübesi,
- Satışların azalması,
- Giderlerin artması,
- Diğer muhtelif faktörler.

Söz konusu rapora göre, işletme başarısızlığının en önemli nedeni olarak ekonomik faktörler gösterilirken, ikinci sırada yönetim tecrübesi yer almaktadır. Başarısızlığın işletme dışı ve işletme içi nedenleri aşağıda genel hatlarıyla açıklanmaktadır.

1.1.2.1. İşletme Dışı Nedenler

İşletmeler, içinde faaliyet gösterdikleri çevreden etkilenen ve bu çevreyi etkileyen iktisadi birimlerdir. Bundan dolayı, işletme başarısızlığına neden olabilecek faktörlerden bazıları da işletmenin kontrolü dışındaki çevresel faktörlerdir. Bu tür faktörleri önlemek mümkün olmamasına rağmen, etkilerini azaltacak bazı tedbirler almak mümkündür.

İşletmeleri başarısızlığa götüren çevresel faktörler aşağıda anlatılmaktadır:

⁷ Charles Thevnin; A Comparative Examination of Bankruptcy Prediction: Altman MDA Study Versus Luther ANN Study: A Test of Predictive Strength Between The Two Techniques, Doctorate Dissertation, Nova Southeastern University, 2003, p.15.

1- Toplumsal Çevre

İşletme dışı başarısızlık nedenlerinden biri, işletmenin faaliyet gösterdiği toplumsal ortamdır. Toplumun geneli tarafından benimsenen davranış kalıpları, ekonomik koşullarla birleşerek işletmenin faaliyetlerine yön verir⁸.

İşletmeler başarılı olabilmek için toplumun beklentilerini bilmek ve bu beklentilere uygun olarak faaliyetlerini devam ettirmek zorundadırlar. Tekelci uygulamalardan kaçınmak, kaliteli mal veya hizmet üretmek, tüketici haklarına saygılı olmak, çevreye karşı duyarlı olmak toplumsal çevrenin beklentilerinden bazılarıdır⁹.

2- Yasal ve Politik Çevre

İşletmelerin faaliyetlerini sürdürmeleri esnasında ve ilişkilerinde uymaları gereken bir takım yasalar (ticaret kanunu, vergi kanunu, borçlar kanunu, icra ve iflas kanunu vb.) bulunmaktadır. İşletmelerin bu yasaları ihlal etmeleri çeşitli cezalara maruz kalmalarına, itibarlarını yitirmelerine ve dolayısıyla başarısız olmalarına neden olabilmektedir¹⁰.

3- Ekonomik Çevre

İşletmeler ekonomik sistemin bir parçasıdır ve faaliyette buldukları ülkenin ekonomik koşullarından etkilenirler.

İşletmenin olumsuz durumlar ile karşılaşmasına neden olabilecek faktörler; faiz oranlarındaki ani yükseliş veya azalış, enflasyon oranındaki beklenmedik değişiklikler, döviz kurlarındaki ani dalgalanmalar, ithalat ve ihracat rejiminde yapılan değişiklikler ve uygulanan para politikaları şeklinde sıralanabilir¹¹.

İşletmeler toplumun ihtiyacını karşılamak için bir yandan pazara mal ve hizmet sunarken, diğer yandan üretim yapabilmek için aynı pazardan emek, sermaye ve doğal kaynaklar gibi girdileri talep etmektedirler. Dolayısıyla işletmeler bir yönüyle arzın

⁸ Semih Büker; Rıza Aşıkoğlu; Güven Sevil; Finansal Yönetim, 2. Baskı, Anadolu Üniversitesi, Eskişehir, 1997, s.524.

⁹ R. Metin Türko; Finansal Yönetim, Alfa Yayın, İstanbul, 1999, s.599.

¹⁰ A.g.e., s.600.

¹¹ Büker; a.g.e., s.526.

diğer yönüyle talebin dışında değildirler. İşletmeler topluma mallarını sunmakta ve karşılığında para almakta iken, toplum da işletmeye işçilik sunmakta ve karşılığında ücret almaktadır. Bu döngü ekonominin işleyişini sağlamaktadır¹².

Ekonominin işleyişinde çoğu durumda devletin de belirleyici rolü bulunmaktadır. Her ne kadar, serbest piyasa ekonomisi kuralları çerçevesinde devletin ekonomideki rolü azalsa da, ülke ekonomisinin geleceğini belirleyecek makro ekonomik kuralları devlet koymaktadır. Devlet, ithalat - ihracat rejimini, faiz oranlarını, vergi mevzuatını, mali yardım ve destekleri belirleyerek işletmelerin faaliyetlerini etkilemektedir¹³.

4- Doğal Çevre

İşletmeler açısından doğal çevre, üretimde kullanılan doğal kaynakları ifade etmektedir. Doğal çevrenin sürekli olarak değişmesi ve gelişmesi, işletmeler için bazı fırsatlar sunabileceği gibi başarısız olmalarına da neden olabilmektedir. Doğal çevre, özellikle doğal kaynakların tükenmesi ve çevre kirliliği gibi nedenlerden dolayı işletme faaliyetleri üzerinde etkili olmaktadır¹⁴. Ayrıca, deprem, su baskını gibi işletmenin başarısızlığına neden olabilecek doğal afetleri de bu faktörler arasında saymak gerekmektedir.

1.1.2.2. İşletme İçi Nedenler

İşletmenin kontrolü altındaki işletme içi faktörlerin sayısı oldukça fazla olmakla birlikte, genel hatlarıyla aşağıdaki başlıklar altında toplanabilirler¹⁵:

- 1) Kötü yönetim,
- 2) Çevredeki değişime uyum gösterememe,

¹² Demir, Hüseyin; "İşletmelerde Başarısızlığın Nedenleri ve Çıkış Yolları", Dış Ticaret Dergisi, Temmuz 1997, Erişim Adresi: <http://www.foreigntrade.gov.tr/ead/-DTDERGI/tem97/4.htm>.

¹³ A.g.e.

¹⁴ Türko; a.g.e.,s.600.

¹⁵ Yasemin Keskin; İşletmelerde Finansal Başarısızlığın Tahmini, Çok Boyutlu Model Önerisi ve Uygulaması, Doktora Tezi, Hacettepe Üniversitesi, Temmuz 2002, s.16.

- 3) Yetersiz iletişim,
- 4) Sağlıksız büyüme,
- 5) Ana projelerde başarısızlık.

Yapılan çalışmalar, işletme başarısızlığının temel nedeninin, yönetimin yetersizliği olduğunu ortaya koymaktadır. İşletmeleri finansal başarısızlığa götüren yönetim hataları şu şekilde sıralanabilir¹⁶:

- Finansal planlamanın yetersiz oluşu, finansman gereksinimleriyle kaynaklar arasında dengenin kurulamayışı, kaynakların süreleri ile bunların yatırıldıkları varlıkların kullanım süreleri arasında uyumsuzluk bulunması,
- İşletmenin olanaklarının çok üzerinde büyümesi ve bunun sonucu aşırı borçlanma ve öz kaynak yetersizliği sorunu ile karşılaşması,
- Sabit nitelikteki giderlerin, işletmenin taşıyabileceğinin çok üstünde bir yük oluşturması,
- Yükümlülüklerin yerine getirilmesi konusuna gereken özen ve titizliğin gösterilmemesi, yükümlülüklerin yerine getirilmesi için gerekli önlemlerin zamanında alınmaması,
- Satış, üretim ve finans bölümleri arasında gerekli koordinasyonun sağlanamaması,
- Yeni ürünler geliştirilememesi,
- Tasarım, dizayn ve ürün geliştirme çalışmalarının maliyet, kârlılık ve pazarlama düşüncelerinden bağımsız olarak yürütülmesi,
- İşletme faaliyetlerinin yeterince çeşitlendirilmemesi,
- İlgili endüstri kolundaki gelişmelerin yakından izlenmemesi,

¹⁶ Öztin Akgüç; Finansal Yönetim, Yenilenmiş 7. Baskı, Avcıol Basım-Yayın, İstanbul, 1998, pp.948-949; Türko; a.g.e., ss.598-599.

- Müşteriler hakkında yeterli bilgi toplamadan kredili satış hacminin genişletilmesi,
- Pazar arařtırmalarına gereken önemin verilmemesi,
- Üretilen mal ve hizmetlerin tek veya belirli sayıda alıcıya satılması,
- Girdi sağlanması konusunda az sayıda işletmeye baęlı kalınması,
- Üst düzey yöneticiler arasında, temel sorunlarda görüş ayrılıkları olması nedeniyle uyumlu bir işbirliği anlayışı içinde işletme faaliyetlerinin yürütülememesi,
- Yönetim faaliyetlerinde koordinasyon yetersizliği,
- Yöneticilerde teknik bilgi noksanlığı,
- Olumsuz gelişmelere karşılık yöneticilerin zamanında ve yerinde etkili önlemler alamamaları,
- İşletmenin tüm yönetiminin ayrıntıya inen konulara kadar tek bir elde toplanması.

Yukarıda sayılan yönetim hataları, işletmeleri başarısızlığa götüren en genel nedenler olarak görülmektedir. İşletme başarısızlığının nedenlerinin doğru olarak bilinmesi, alınacak önlemlerin belirlenmesi açısından da son derece önemlidir.

1.1.3. Finansal Başarısızlığı Önleme Yolları

İşletmelerde başarısızlığı önlemek için izlenebilecek çok sayıda yol bulunmaktadır. Bu husus, tek başına bir araştırma konusu olabilecek genişliktedir. Bu nedenle, burada sadece finansal önlemlerin sıralanmasıyla yetinilmiştir. Söz konusu önlemlerden bazıları şunlardır¹⁷:

- Borçların vadesini uzatmak,
- Borçları konsolide etmek veya yeniden yapılandırmak,
- Alacaklıların anlaşma sonucunda alacaklarının bir bölümünden vazgeçmeleri,

¹⁷ Akgüç; a.g.e., ss.949-956.

- 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 kıymet haline dönüştürülmesi,
- Konkordato önerilmesi,
- İşletmenin yasal statüsünü değiştirmesi,
- İşletmenin diğer bir işletmeyle birleşmesi,
- Bazı işletmelerin tamamen veya kısmen satılması,
- İşletmenin tasfiyesi.

Başarısızlığa düşen bir işletmede, yukarıda sayılan önlemlerden hangisine başvurulacağı, o işletmenin başarısızlığına neden olan faktörlerle doğrudan ilgilidir. Bu nedenle, öncelikle işletmenin başarısızlığının nedenleri ayrıntılı olarak incelenmeli ve daha sonra en uygun görülen önlem uygulamaya konulmalıdır.

1.2. FİNANSAL BAŞARISIZLIK TAHMİNİ

1.2.1. Finansal Başarısızlığın Tahmin Edilmesinin Önemi

İşletme başarısızlığı, çeşitli grupları ilgilendiren ve büyük maliyetler ihtiva eden bir kavramdır. Bu nedenle, finansal başarısızlığın tahmin edilmesi, gerek gelecekte başarısız olacağı tahmin edilen işletmelerde koruyucu ve düzeltici önlemler alabilmek, gerekse kötü performans gösteren işletmeleri tespit edebilmek açısından son derece önemlidir. İşletmenin başarısı, işletme ile ilgili grupları yakından ilgilendirmektedir. Finansal açıdan sorun yaşayan bir işletmenin piyasa değerinin büyük ölçüde azaldığını

gösteren pek çok kanıt bulunmaktadır. Söz konusu durum, işletme ile ilgili grupların her birini ciddi şekilde etkileyebilmektedir. Bu nedenle, işletme başarısızlığının toplam maliyeti sanıldığından çok daha büyük olabilmektedir. Yeniden yapılandırma aracılığıyla işletme başarısızlığının önlenildiği durumlarda bile, yeniden yapılandırmanın maliyetleri oldukça yüksektir. Yapılan bir çalışmada, söz konusu maliyetlerin işletme değerinin % 12'si ile % 19'u arasında değiştiği tespit edilmiştir¹⁸.

İşletme başarısızlığı, sadece işletmenin doğrudan çevresi için değil, genel ekonomi için de çeşitli maliyetler ortaya çıkarmaktadır. Geniş çevreye sahip bir işletmenin başarısız olmasının maliyetleri, "yayıma etkisiyle" tüm ekonomide negatif bir etki oluşturabilir. Böylece, işletme başarısızlığı, istihdam ve ekonomik refahla ilgili olumsuz sonuçlara neden olabilir¹⁹. Sonuç olarak, işletme başarısızlığının tahmini, sadece bireysel bakış açısıyla belirli kişi ya da gruplar için değil, bir bütün olarak toplum için de önemlidir.

Bir ülkede, başarısız işletmelerin sayısının çok olması, ciddi refah kayıpları ve makroekonomik sorunlar yaratabilmektedir. Özellikle ülke için önemli sektörler, sektöre özgü veya ekonomiye özgü koşullardan olumsuz etkilendiğinde çok sayıda işletme tasfiye edilebilir. Bu durum, bankaların sermayesini aşındırarak bankacılık sistemini zayıflatabilir ve finansal krizleri tetikleyebilir. Çünkü başarısız işletmeler, kullanılabilir kredilerin azalmasına neden olarak, kaynakların daha değerli yatırım fırsatlarında kullanılmasını engeller. Bu durum kaynakların etkin olarak kullanılmamasına yol açar²⁰. Bir ülkede, başarısız işletme sayısındaki artış istihdam üzerinde de olumsuz bir etki yaratmaktadır. Başarısız işletmelerin sayısının artması, işsizlik oranının artmasına neden olacaktır.

Ayrıca geçtiğimiz yüzyılda, işletmelerin içinde faaliyet gösterdiği çevre ve koşullar, önemli ölçüde değişmiştir; öyle ki işletmeler küresel bir ekonomide faaliyet göstermeye başlamışlar ve rekabet çok daha güçlü bir hal almıştır. Bazı ülkelerde, iflas oranları

¹⁸ Anthony Brabazon; Michael O'Neill; Robin Matthews et Al; "Grammatical Evolution and Corporate Failure Prediction" (Proceedings of the Genetic and Evolutionary Computation Conference (GECCO 2002)), Spector et. al. Eds., New York, July 9-13, 2002, p.1011.

¹⁹ Yuriy Andreev Andreev; "Predicting Financial Distress of Spanish Companies", III Jornada De Pre-Comunicaciones A Congresos De Economía Y Administración De Empresas, 29 de Junio de 2006, p.2.

²⁰ Hunter; Isachenkova; a.g.e., p.4.

anormal şekilde yükselmiş ve pek çok işletme başarısızlığa karşı daha kırılğan hale gelmiştir²¹. Bütün bu gelişmeler, finansal başarısızlık tahmininin önemini daha da artırmaktadır.

Piyasa eksikliklerinin ve asimetrik bilginin etkileri üzerinde yapılan çalışmalar da finansal başarısızlık tahmininin önemini ortaya koymaktadır. Finansal piyasaların kusursuz olduğunu varsayan Modigliani ve Miller (1958)'in aksine, günümüzde finansal piyasaların kusursuz olmadığı açıktır. Piyasada bulunan fonlar, kârlı ve iyi projelerin (pozitif net bugünkü değere sahip projeler) tamamını fonlamak için yetersizdir. Bu nedenle, değer yaratabilecek nitelikte olmasına rağmen bazı projelerden vazgeçilebilmektedir. Örneğin, bankacılık piyasasında sermaye kısıtlıdır ve asimetrik bilgiden dolayı borçlar çeşitli kriterlere göre dağıtılabilir. Bu bağlamda fon veya sermaye tedariki, beklenen getiriye ve projelerin başarılı olma olasılığına bağlıdır. Dolayısıyla, sadece en yüksek beklenen getiriye sahip projeler gerekli fon ve sermayeyle donatılacaktır. Bu açıdan bakıldığında, işletmelerin ve onların projelerinin risk değerlemesi hayati öneme sahip gözükmektedir. Üstelik başarısızlık tahmin modellerinin kullanılması, fon tedarikçileri ve işletme yönetimi arasında bulunan bilgi asimetrisini de azaltabilmektedir²².

Çıkar grupları tarafından işletme ile ilgili verilebilecek kararları, amacına göre üç grupta toplamak mümkündür. Bunlar; yönetim, yatırım ve kredi kararlarıdır. Finansal başarısızlık tahmini, söz konusu kararların daha doğru ve etkin olarak verilmesinde de önemli rol oynamaktadır. Başarısızlık tahmininin, bu kararlar açısından önemi aşağıda anlatılmaktadır:

Yönetim Kararları Açısından Önemi: Daha önce de belirtildiği gibi, yapılan çalışmaların pek çoğu, başarısızlığın en önemli nedeninin işletme yönetimi olduğu sonucuna ulaşmıştır. Başarısızlığı önceden doğru olarak tahmin eden bir model, hiç kuşkusuz yöneticiler için karar vermede çok faydalı bir araç olacaktır. Yöneticiler, finansal başarısızlık tahmin modellerinden yararlanarak olası bir başarısızlığın önlemini alabileceklerdir.

²¹ Andreev; a.g.e., pp.2-3.

²² A.g.e., p.2.

Finansal başarısızlığın önceden tahmin edilmesi, yöneticiye kendi işletmesinin durumu hakkında tarafsız bir bilgi sağlayacağı gibi, iş ilişkisi içerisinde bulunduğu işletmeler hakkında da doğru kararlar vermesine yardımcı olacaktır.

Yatırım Kararları Açısından Önemi: Günümüzde işletmeler, sermaye ihtiyaçlarını birtakım finansal kuruluşlardan ya da çeşitli menkul kıymetler aracılığıyla çok sayıda küçük yatırımcıdan karşılamaktadırlar. Bu da, çok sayıda üyeden oluşan geniş bir yatırımcı grubunu ortaya çıkarmıştır. Gerek bir işletmeye yatırım yapmış olan mevcut yatırımcılar, gerekse yatırım yapmayı düşünen potansiyel yatırımcılar kararlarını verirken işletme ile ilgili bilgilerden büyük ölçüde yararlanmaktadır. Bu bilgilere ilaveten, başarısızlığın doğru olarak tahmin edilmesine olanak sağlayan bir model, hiç kuşkusuz yatırım kararlarının doğru olarak verilmesini sağlayacaktır.

Finansal başarısızlık tahmin modelleri yardımıyla yatırımların verimli ve uygun alanlara kanalize edilmesi, yatırılabilir fonların optimal kullanımına neden olacak ve ülke ekonomisi açısından da önemli yararlar sağlayacaktır.

Kredi Kararları Açısından Önemi: Kredi kararlarının doğruluğu, kredi verenler açısından olduğu kadar, genel ekonomi açısından da son derece önemlidir. Yanlış bir karar, kredi verenin faiz gelirinden mahrum kalmasına ve anaparayı kaybetmesine neden olabileceği gibi, batık kredilerin sayısındaki artış genel ekonomi açısından da ciddi sorunlar doğurabilecektir.

Kredi veren kurumlar, özellikle de bankalar, yeni bir kredi verecekleri zaman ya da mevcut bir kredinin vadesini uzatmadan önce, potansiyel müşterinin krediyi geri ödemede temerrüde düşme olasılığını tahmin etmeye çalışırlar²³. Başarılı bir tahmin modeli sayesinde, kredi verme kararları daha sağlam temellere oturtulabilir ve dolayısıyla önemli tasarruflar sağlanabilir.

T.C.M.B.'nin, kullandıkları kredilerin toplam tutarı 10 milyar TL'yi aşan şirketlerin kredilerini dikkate alarak hazırladığı rapora göre; bankalar ile özel finans kuruluşlarının şirketlere kullandırdıkları toplam nakit krediler, 2002 yılı şubat ayı sonunda yaklaşık 42

²³ Amir F. Atiya; "Bankruptcy Prediction for Credit Risk Using Neural Networks: A Survey and New Results", IEEE Transactions On Neural Networks, Vol. 12, No. 4, July 2001, p.929.

katrilyon 851 trilyon TL olmuştur. Bu kredilerin 4 katrilyon 345 trilyon TL'lik bölümünü, şirketlerden zamanında tahsil edilemediği için “batık” duruma gelen krediler oluşturmuştur. Böylece, batık kredilerin toplam nakit krediler içerisindeki payı % 10,1 olarak gerçekleşmiştir²⁴. Bu rakam finansal başarısızlık tahmininin potansiyel etkisi hakkında bir fikir edinmemize yardımcı olabilir. Finansal başarısızlık tahminindeki olumlu gelişme, trilyonlarca lira tasarrufa neden olacaktır.

Kredi kararlarını doğru olarak verebilmek amacıyla, çok sayıda bankanın yıllardır diskriminant analizi ve lojistik regresyon analizi gibi tekniklerden, son yıllarda da yapay sinir ağlarından yararlandıkları bilinmektedir. Chase Manhattan Bank'ın kredi taleplerini değerlendirmede, SEC (Securities and Exchange Commission)'in de hisse senetlerini izlemeye ve analiz etmeye yapay sinir ağı kullandıkları bilinmektedir²⁵. Başarısız işletmelerin önceden tahmin edilmesi için kurulmuş bir model, hiç şüphesiz kredi verenler için de önemli bir araçtır. Ancak, bu araçların kredi uzmanlarının yerini almasını beklemek yanlıştır. Bununla birlikte, uzmanların kredi taleplerini değerlendirirken bu araçları kullanmaları onlara daha doğru karar vermelerinde yardımcı olabilecektir.

Finansal başarısızlık tahmin modelleri, kredi verenler tarafından potansiyel problemleri kredilerden kaçınmanın yanı sıra başka amaçlarla da kullanılabilir. Örneğin, kredi alan işletmenin, kredi değerini yansıtacak şekilde uygulanacak faiz oranının hesaplanmasında ya da banka kredi portföyünün kredi riskini doğru olarak değerlendirmede de kullanılabilir. Kredi riskinin doğru olarak değerlendirilmesi, hedeflenen risk/getiri özelliklerini başarabilmek için bankaların gelecekteki kredi işlemlerini planlamasına da olanak tanımaktadır²⁶.

²⁴ Hürriyet Gazetesi, Erişim Adresi: <http://webarsiv.hurriyet.com.tr/2002/04/07/109512.asp>.

²⁵ Rodney Stacey Brooks Bullock; Forecasting Bankruptcy to Promote Organizational Survival: A Comparison of Neural Network and Discriminant Analysis Methodologies, Doctorate Dissertation, Walden University, August 1999, p.26.

²⁶ Atiya, a.g.e., p.929.

1.2.2. Finansal Başarısızlık Tahmin Modellerinin Gelişimine Katkıda Bulunan Faktörler

Finansal başarısızlık, tek başına başarısızlığa neden olabilecek bir olaydan (bir ortağın ölümü, yangın, dolandırıcılık, hırsızlık ve doğal afetler gibi²⁷) kaynaklanabileceği gibi, uzun bir gerileme sürecinin nihai sonucu da olabilir. Bir işletmenin tek bir olaydan dolayı ani olarak başarısızlığa uğraması, çok istisnai bir durumdur. Başarısızlığa doğru giden bir işletme, genellikle önceden bazı sinyaller, uyarı işaretleri vermeye başlamaktadır. İşletmenin bazı finansal oranlarındaki olumsuz gelişmeler, hisse senetleri fiyatlarındaki devamlı ve hızlı düşüş, işletmenin bankalardaki kredi limitlerini aşarak borçlanması, işletmenin kasasındaki ve bankalardaki nakit miktarının düşük seviyelere inmesi ve bu durumun uzun süre devam etmesi, ödemelerde gecikmeler vb. faktörler işletmelerin başarısızlığa doğru gittiklerinin göstergeleridir²⁸. Bu bakış açısı altında, bazı sinyaller ve uyarı işaretleri aracılığıyla işletmenin durumunun önceden tahmin edilmesi mümkündür.

İşletmenin gelecekteki durumuyla ilgili tahminde bulunmak gereksinimi hisseden çıkar grupları, uzun yıllar boyunca işletmelerin finansal durumunu analiz etmek ve finansal sıkıntıyı ölçmek için daha doğru yöntemler araştırmışlardır. Geleneksel olarak, işletmenin durumu analiz edilirken ve geleceğe yönelik öngörülerde bulunulurken bilanço ve gelir tablosu ile bu tablolarda yer alan kalemlerden hesaplanan oranlar kullanılmıştır.

Bugüne kadar bu alanda yapılan çalışmaların çoğu, finansal oranların, işletmelerin başarılı veya başarısız olduğunu ortaya koyma yeteneğine sahip olduğunu göstermektedir. Özellikle, Altman'ın (1968)²⁹ yayınladığı çalışma bu alanda yeni ufuklar açmıştır. Altman, işletmelerin finansal durumunu değerlendirmede daha güçlü bir yaklaşım ortaya koyabilmek için geleneksel finansal oranlarla istatistiki modellerin

²⁷ Rob Holland; "Planning Against A Business Failure", Agriculture Development Center, Info#24, October 1998, p.2.

²⁸ Akgüç; a.g.e., s.949.

²⁹ Edward I. Altman; "Financial Ratios, Discriminant Analysis and The Prediction of Corporate Bankruptcy", The Journal of Finance, Vol. XXIII, No. 4, 1968, pp.589-609.

kullanımını birleştirmiştir. Altman'ın çalışması istatistiki yöntemlerin kullanılması konusunda öncü olmuştur. Bu çalışmayla birlikte, işletme başarısızlığının tahmini konusu, finansmanda ana araştırma alanlarından biri haline gelmiştir. Başta akademisyenler olmak üzere, farklı ülkelerden çok sayıda araştırmacı, çeşitli modelleme tekniklerine dayanan finansal başarısızlık tahmin modelleri geliştirmişlerdir. Bu alandaki gelişmelere neden olan önemli faktörler aşağıda genel hatlarıyla anlatılmaktadır.

Verilerin ulaşılabilirliği ve istatistiki tekniklerdeki gelişmeler, finansal başarısızlık tahmin modelleri kurma konusundaki olanakları artırmıştır. Matematik, istatistik, bilişim ve yapay zeka gibi alanlardaki ilerlemeler, başarısızlık tahmin modellerinin geliştirilmesinde yeni teknikler kullanılmasına olanak sağlamıştır. Ayrıca, bazı şirketlerin verileri halka ilan edilmeye başlanmış ve araştırmacıların kullanabileceği standart finansal verilerin yer aldığı büyük veri tabanları kurulmuştur³⁰.

Finansal başarısızlık tahmin modellerinin gelişimine katkıda bulunan diğer bir faktör, tahmin modellerinin gerekliliğinin ispatlanmış olmasıdır. Bir işletmenin finansal durumunu değerlendirmede, denetçilerin ve uzmanların görüşleriyle modellerin tahminlerini karşılaştıran araştırmalar yapılmıştır. İlk bakışta denetçilerin ve uzmanların daha doğru bir değerlendirme yapmaları beklenmektedir. Buna rağmen pek çok araştırma, başarısız şirketlerin sınıflandırılmasında tahmin modellerinin denetçi ve uzman görüşlerinden daha iyi performansa sahip olduklarını göstermiştir³¹.

1.2.3. Finansal Başarısızlık Tahmin Çalışmaları

Önceki kısımda anlatılan nedenlerden ve gelişmelerden dolayı, finansal başarısızlığın tahmin edilmesi, uzun yıllar boyunca finans alanında önemli araştırma konularından biri olmuştur. Burada, finansal başarısızlık tahmin alanında yapılan çalışmalar, kronolojik bir sıraya göre anlatılacaktır. Farklı veriler, farklı yöntemler ve farklı zaman dilimleri

³⁰ Andreev; a.g.e., p.3.

³¹ Sofie Balcaen; Hubert Ooghe; "35 Years of Studies on Business Failure: An Overview of the Classical Statistical Methodologies and Their Related Problems", Universiteit Gent Working Paper: 2004/248, June 2004, p.4.

için yapılmış pek çok çalışma bulunduğundan, burada sadece sonuçları ve bu alana olan katkıları bakımından önemli bulunan çalışmalara yer verilmektedir.

Finansal başarısızlık tahmini alanında yapılan ilk çalışmalar: Ramser ve Foster (1931), Fitzpatrick (1932), Winakor ve Smith (1935), Merwin (1942) olarak bilinmektedir³². Bu çalışmalar, hiçbir istatistiki yöntem kullanmaksızın sadece başarısız ve başarılı işletmelerin finansal oranlarını karşılaştırmaktadırlar.

Beaver (1966)³³, istatistiki bir teknik kullanarak iflas tahminini inceleyen ilk araştırmacıdır. Beaver, yöntem olarak, tek değişkenli diskriminant analizini kullanmıştır. Bununla birlikte, finansal oranları teker teker incelemeye ve her bir oran için bir kopuş değeri geliştirmeye dayanan Beaver'in analizi oldukça basittir. Yine de, çeşitli finansal oranların başarısızlıktan beş yıl öncesine kadar faydalı göstergeler olabileceği sonucuna ulaşmıştır.

Finansal başarısızlık tahmini alanında, dönüm noktası olarak görülen çalışma ise Altman'ın 1968 yılında yaptığı çalışmadır. Altman'ın Z-skor modeli, finansal başarısızlık tahmin alanında daha sonra yapılan çalışmalara öncülük etmiştir. Bu alanda yapılan çalışmalarda, en çok atıfta bulunulan eserdir. Ayrıca, diğer istatistiki modelleri öneren çalışmalar için de bir temel teşkil etmiştir. Z-skor modelinin ortaya koyduğu en önemli fikir, bir işletmenin muhasebe verilerinin çok değişkenli tekniklerle birleştirildiğinde, işletmenin finansal durumu hakkında faydalı bilgiler sağladığıdır³⁴.

Altman, çalışmasında finansal başarısızlık kriteri olarak iflas kavramını kullanmıştır. 1946-1965 yılları arasında, 33 iflas etmiş ve 33 iflas etmemiş üretim işletmesi üzerinde yapılan çalışma, 22 oranla başlamış ve çalışmanın sonucunda aşağıdaki 5 değişkenli diskriminant modeli elde edilmiştir³⁵:

³² Mine Uğurlu; Hakan Aksoy; "Prediction of Corporate Financial Distress in an Emerging Market: The Case of Turkey", Cross Cultural Management: An International Journal, Vol. 13, No. 4, 2006, p.277.

³³ William H. Beaver; "Financial Ratios as Predictors of Failure", Empirical Research in Accounting: Selected Studies, Journal of Accounting Research, Supplement to Vol. 5, 1966, pp.71-111.

³⁴ Thevnin; a.g.e., p.8.

³⁵ Altman; a.g.e., pp.589-609.

$$Z = 0,012 X1 + 0,014 X2 + 0,033 X3 + 0,006 X4 + 0,999 X5$$

Burada;

X1; Net İşletme Sermayesi / Toplam Varlıklar

X2; Dağıtılmayan Karlar / Toplam Varlıklar

X3; Faiz ve Vergi Öncesi Kar / Toplam Varlıklar

X4; Öz Kaynaklar / Toplam Borçlar

X5; Net Satışlar / Toplam Varlıkları temsil etmektedir.

Altman'ın çalışmasında kullanılan kopuş değerleri 1,81 ve 2,675'tir. Diskriminant skoru 1,81'in altında olan işletmeler iflas eden işletmeler grubuna, 2,675'in üzerinde olan işletmeler ise başarılı işletmeler grubuna sınıflandırılmaktadır. 1,81 ve 2,675 arasındaki alan ise gri bölgeyi temsil etmektedir. Altman, geliştirmiş olduğu bu modelle iflas eden işletmeleri iflastan bir yıl önce % 95, iflastan iki yıl öncesinde ise % 83 doğrulukla sınıflandırmayı başarmıştır.

Altman'ın çalışmasını takiben, 1980'li yıllara kadar diskriminant analizi finansal başarısızlık tahmin alanına hakim olmuştur. Farklı veriler ve farklı değişkenler üzerinde diskriminant analizini kullanan pek çok çalışma yapılmıştır. Bunlar arasında, Deakin (1972)³⁶, Edmister (1972)³⁷, Moyer (1977)³⁸, Karels ve Prakash (1987)³⁹'in çalışmaları dikkate değerdir.

Ohlson (1980), finansal başarısızlığın tahmini problemine lojistik regresyon yaklaşımını getirmiştir. Ohlson, 1970-1976 yılları arasından seçtiği 105 iflas etmiş ve 2058 iflas

³⁶ Edward B.Deakin; "A Discriminant Analysis of Predictors of Business Failure", Journal of Accounting Research, Vol. 10, No. 1, 1972, pp.167-179.

³⁷ Robert O. Edmister; "An Empirical Test of Financial Ratio Analysis for Small Business Failure Prediction", Journal of Financial Quantitative Analysis, Vol. 2, March 1972, pp.1477-1493.

³⁸ R. Charles Moyer; "Forecasting Financial Failure: A Re-Examination", Financial Management, Spring 1977, pp.11-17.

³⁹ Karels; Prakash; a.g.e., pp.573-593.

etmemiş işletmenin verilerine lojistik regresyon analizini uygulamıştır. Lojistik regresyon analizinin tercih edilmesinin nedeni, çok değişkenli diskriminant analiziyle ilgili sınırlayıcı varsayımlardan ve problemlerden kaçınmaktır. Ohlson iflastan bir yıl öncesi için, iflastan iki yıl öncesi için ve iflastan bir ve iki yıl öncesini birleştirerek üç farklı model geliştirmiştir. Modeller, sırasıyla % 96,12; % 95,55 ve % 92,84 oranında başarıyla tahminde bulunmuşlardır⁴⁰.

Ohlson'un çalışmasından sonra, bir gözlemin bir gruba ait olma koşullu olasılığını sağlayan logit ve probit analizi kullanılarak çeşitli tahmin modelleri geliştirilmiştir. Bunların en önemlileri; Mensah (1983)⁴¹, Zavgren (1985), Zavgren (1988), Keasey ve Watson (1987)⁴², un çalışmalarıdır.

Literatürde diskriminant analizi, lojistik regresyon analizi ve probit analizi gibi istatistiki yöntemlerin finansal başarısızlık tahmini alanındaki performanslarını karşılaştıran çok sayıda çalışma bulunmaktadır. Collins ve Green (1982), Gentry, Newbold ve Whitford (1985), Gentry, Newbold ve Whitford (1987)⁴³, Harris (1989), Theodossiou (1991) ve Aktaş (1991)⁴⁴, Uğurlu ve Aksoy (2006)⁴⁵, un çalışmaları bunlardan bazılarıdır. Elde edilen sonuçlar, çeşitli istatistiki yöntemler arasında çok küçük farklar bulunduğunu göstermektedir. Bu nedenle, çeşitli istatistiki tekniklerle ilgili sınırlayıcı varsayımlar ve istatistiksel hususların, sadece tahmin gücünü dikkate alan kullanıcılar açısından çok fazla önem taşımadığı söylenebilir⁴⁶.

⁴⁰ James A. Ohlson; "Financial Ratios and the Probabilistic Prediction of Bankruptcy", Journal of Accounting Research, Vol. 18, No. 1, 1980, pp.109-131.

⁴¹ Yaw M. Mensah; "The Differential Bankruptcy Predictive Ability of Specific Price Level Adjustments: Some Empirical Evidence", The Accounting Review, Vol. LVIII, No. 2, April 1983, pp.228-246.

⁴² K.Keasey; R. Watson; "Non-Financial Symptoms an the Prediction of Small Company Failure: A Test of Argenti's Hypotheses", Journal of Business Finance & Accounting, Vol. 14, No. 3, 1987, pp.335-354.

⁴³ James A. Gentry; Paul Newbold and David T. Whitford; "Funds Flow Components, Financial Raitos and Bankruptcy", Journal of Business Finance & Accounting, Vol. 14, No. 4, 1987, pp.595-606.

⁴⁴ Ramazan Aktaş; Endüstri İşletmeleri İçin Mali Başarısızlık Tahmini-Çok Boyutlu Model Uygulaması, Doktora Tezi, Ankara Üniversitesi, Ankara, 1991.

⁴⁵ Uğurlu; Aksoy; a.g.e., pp.277-295.

⁴⁶ Kevin Keasey; Robert Watson; "Financial Distress Prediction Models: A Review of Their Usefulness", British Journal of Management, Vol. 2, 1991, p.91.

Teknolojik gelişmeyle, özellikle de bilgisayar alanındaki hızlı gelişmeyle birlikte yapay zeka kavramı ortaya çıkmıştır. Yapay zeka teknolojilerinden birisi de, insan beyninin işlevlerini taklit etmeye yönelik olarak geliştirilmiş yapay sinir ağlarıdır. Özellikle 1980'li yıllardan itibaren mühendislik, tıp, savunma gibi çeşitli alanlarda kullanılmaya başlanan yapay sinir ağlarının, finansal başarısızlık tahmini alanındaki uygulamaları 1990'da başlamıştır ve halen yoğun bir şekilde devam etmektedir.

Finansal başarısızlık tahmini alanında yapay sinir ağlarını kullanan ilk çalışma, Odom ve Sharda (1990) tarafından yapılmıştır. Söz konusu çalışmada geri yayılım algoritması kullanan bir yapay sinir ağı kullanılmıştır. Bu çalışmanın, yapay sinir ağı metodolojisinin finans problemlerine uygulanabilirliğini göstermek amacıyla basit bir şekilde yapıldığı unutulmamalıdır. Bu nedenle, Odom ve Sharda yapay sinir ağının girdileri olarak, sadece Altman'ın modelinde yer alan beş finansal oranı kullanmışlardır. Çalışmalarını, 128 işletmeden oluşan bir örnek üzerinde geliştiren araştırmacılar, eğitim setindeki iflas etmiş/iflas etmemiş işletmeler oranını değiştirerek çeşitli deneyler gerçekleştirmişlerdir. Elde edilen sonuçlar çok değişkenli diskriminant analizi ile karşılaştırılmıştır. Çok değişkenli diskriminant analizi iflas etmiş işletmeleri % 59,26 - % 70,37 ve iflas etmemiş işletmeleri ise % 78,57 - % 89,29 aralığında doğru tahmin etmiştir. Buna karşılık yapay sinir ağları, eğitim setine bağlı olarak iflas etmiş işletmeler için % 77,78 - % 81,48 aralığında, iflas etmemiş işletmeler içinse % 78,57 - % 85,71 aralığında sınıflandırma doğruluğu elde etmiştir⁴⁷. Diskriminant analizi ile karşılaştırıldığında, yapay sinir ağlarının iflas etmiş işletmeleri daha yüksek bir oranda doğru tahmin ettiği görülmektedir.

Raghupathi ve arkadaşları, 1991 yılında sundukları bildiride 102 işletme (51 başarısız ve başarılı işletme çifti) üzerinde geri yayılım algoritması kullanan bir yapay sinir ağı modeli kurmuşlardır. Bu çalışma, yapay sinir ağlarının finansal başarısızlık tahmini için uygun araçlar olduğunu göstermektedir⁴⁸. Aynı yıl, Cadden tarafından yayınlanan

⁴⁷ Marcus D. Odom; Ramesh Sharda.; "A Neural Network for Bankruptcy Prediction", IJCNN International Joint Conference on Neural Networks, Vol. 2, San Diego, CA, 1990, pp. 163-167.

⁴⁸ Wullianallur Raghupathi; Lawrence L. Schkade and Bapi S. Raju; "A Neural Network Application for Bankruptcy Prediction", Proceedings of the 24th Annual Hawaii International Conference on Systems Sciences, Vol. IV, 1991, pp. 147-155.

bildiride 59 işletme üzerinde iki farklı yöntem kullanılarak tahmin modeli geliştirilmiştir. Yapılan karşılaştırma sonucunda, yapay sinir ağlarının diskriminant analizinden daha iyi performans gösterdiği tespit edilmiştir. Cadden, elde ettiği sonuçların, başarılı ve başarısız işletmelerin sınıflandırılmasında yapay sinir ağlarının kullanımını açısından cesaret verici olduğunu belirtmektedir⁴⁹.

Yapay sinir ağlarının, başarısızlık tahmininde kullanılması ile ilgili ümit verici bu çalışmaları takiben, geleneksel istatistiki yöntemlerle yapay sinir ağlarının bu alandaki performanslarını karşılaştıran pek çok çalışma yapılmıştır.

Karşılaştırmalı çalışmalardan çoğu, yapay sinir ağlarının, diskriminant analizi ve lojistik regresyon analizi gibi istatistiki tekniklerin üzerinde performans gösterdiği sonucuna ulaşmıştır. Bu çalışmalardan önemlileri şunlardır: Coats ve Fant (1993)⁵⁰, Fletcher ve Goss (1993), Wilson ve Sharda (1994), Pompe ve Feelders (1997)⁵¹, Jain ve Nag

⁴⁹ David T. Cadden; "Neural Networks and The Mathematics of Chaos – An Investigation of These Methodologies as Accurate Predictors of Corporate Bankruptcy", The First International Conference on Artificial Intelligence Applications on Wall Street, New York, 1991, pp.52-57.

⁵⁰ Coats, Pamela K.; L. Franklin Fant; "Recognizing Financial Distress Patterns Using a Neural Network Tool", Financial Management, Vol. 22, No. 3, 1993, pp.142-155.

⁵¹ P. P. M. Pompe; A. J. Feelders; "Using Machine Learning, Neural Networks, and Statistics to Predict Corporate Bankruptcy", Microcomputers in Civil Engineering, Vol. 12, 1997, pp.267-276.

(1997)⁵², Hekanaho ve diğeri (1998)⁵³, Zhang ve diğeri (1999)⁵⁴, Yıldız (1999)⁵⁵, Zapranis ve Ginoglou (2000)⁵⁶, Keskin (2002)⁵⁷.

Altman ve diğeri (1994), 1000 İtalyan firmasından oluşan geniş bir örnek üzerinde başarısızlığın bir yıl öncesinden tahmini için yapay sinir ağı ve çok değişkenli diskriminant analizini uygulamışlardır. Çok değişkenli diskriminant analizi biraz daha iyi performans göstermesine rağmen, iki metoddan birinin kesin olarak daha üstün olmadığı sonucuna varılmıştır⁵⁸. Laitinen ve Kankaanpää (1999) de bu çalışmayı destekler niteliktedir ve finansal başarısızlık tahmininde istatistikî yöntemlerle yapay sinir ağları arasında istatistiksel olarak anlamlı bir fark bulunmadığı sonucuna ulaşmışlardır⁵⁹.

Çok az sayıda da olsa, bazı çalışmalarda ise geleneksel istatistikî yöntemlerin yapay sinir ağlarından daha iyi performans gösterdiği sonucuna ulaşılmıştır. 1996 yılında Greenstein ve Welsh tarafından yapılan çalışma bunlardan biridir. Test seti üzerinde

⁵² Bharat A. Jain; Barin N. Nag; "Performance Evaluation of Neural Network Decision Models", Journal of Management Information Systems, Vol.14, No.2, Fall-1997, pp.201-216.

⁵³ Jukka Hekanaho; Barbro Back; Kaisa Sere et Al; "Analysing Bankruptcy Data with Multiple Methods", In Proc. of the 4th International Workshop on Multistrategy Learning (MSL'98), Brescia, Italy, June 1998, 7p.

⁵⁴ Guoqiang Zhang; Michael Y. Hu; B. Eddy Patuwo et Al; "Artificial Neural Networks in Bankruptcy Prediction: General Framework and Cross-Validation Analysis", European Journal of Operational Research, Vol. 116, 1999, pp.16-32.

⁵⁵ Yıldız, Birol; Finansal Başarısızlığın Öngörülmesinde Yapay Sinir Ağı Kullanımı ve Ampirik Bir Çalışma, Doktora Tezi, Dumlupınar Üniversitesi, Kütahya, 1999.

⁵⁶ Zapranis, Achilleas; Demetrios Ginoglou; "Forecasting Corporate Failure with Neural Network Approach: The Greek Case", Journal of Financial Management and Analysis, Vol. 13, No. 2, 2000, pp.11-20.

⁵⁷ Keskin; a.g.e.

⁵⁸ Zhang; Hu; Patuwo et Al; a.g.e., p.21.

⁵⁹ Teija, Laitinen; Maria Kankaanpää; "Comparative Analysis of Failure Prediction Methods: The Finnish Case", The European Accounting Review, Vol. 8, No. 1, 1999, pp.67-92.

yapılan deęerlendirmede, logit modelinin yapay sinir aęından daha iyi performansa sahip olduęu grlmtr⁶⁰.

Yukarıda bahsedilen yapay sinir aęı alımalarının neredeyse tamamında, geri yayılım algoritmasını kullanan ok katmanlı aęlardan yararlanılmıtır. Geri yayılım aęı dıında farklı aę trleri kullanan alımalardan nemlileri aaęıda zetlenmitir.

Back ve dięerleri, 1994 yılında 76 Finlandiya firması zerinde yaptıkları alımalarında farklı yapay sinir aęı trlerini karılatırmılardır. alımanın sonucu, geri yayılım yapay sinir aęlarının dięer trlerden daha iyi performansa sahip olduęunu gstermektedir⁶¹.

Alici (1996), temel bileenler analizi ile yapay sinir aęlarının girdilerini belirlemi ve denetimsiz ęrenme aęlarından kendini rgtleyen haritaları (SOM) kullanmıtır. İngiliz iletmeleri zerinde yapılan alımada, yapay sinir aęı, ok deęikenli diskriminant analizi ve lojistik regresyon teknikleri karılatırılmıtır. ok deęikenli diskriminant analizi iin % 65,6; lojistik regresyon analizi iin % 66 sınıflandırma doęruluęu elde edilirken, sinir aęının bazı parametre varyasyonlarına baęlı olarak % 69,5 - % 73,7 arasında bir sınıflandırma doęruluęuna sahip olduęu grlmtr⁶². Serrano-Cinca, 1996 yılında yaptıęı alımada, iletme baarısızlıklarının tehisi iin karar destek sistemine dayalı bir yapay sinir aęı modeli gelitirmitir. Bu alımada kendini rgtleyen yapay sinir aęı modeli kullanılmıtır⁶³. Kendini rgtleyen haritaları

⁶⁰ Jozef M. Zurada; Benjamin P. Foster; Terry J. Ward et Al; "Neural Networks Versus Logit Regression Models for Predicting Financial Distress Response Variables", The Journal of Applied Business Research, Vol. 15, No. 1, 1998, p.22.

⁶¹ B. Back; G. Oosterom; K. Sere et Al; "A Comparative Study of Neural Networks in Bankruptcy Prediction", Proceedings of the 10th Conference on Artificial Intelligence Research in Finland, Turku, Finland, 1994, 14p.

⁶² Atiya; a.g.e., p.931.

⁶³ Carlos Serrano-Cinca; "Self Organizing Neural Networks for Financial Diagnosis", Decision Support Systems, Vol. 17, 1996, pp.227-238.

kullanan bir diğ er ç alıřma da Kiviluoto'nun 1998 yılında Finlandiya iřletmeleri üzerinde yaptıđı ç alıřmadır⁶⁴.

Lee ve diğ erleri (1996), Kore iřletmelerinin başarısızlık tahmini için yapmıř oldukları ç alıřmalarında, ç ok deđ iřkenli diskriminant analizi, ID3 (bir ç eřit karar ađ acı tekniđ i), kendini örgütleyen haritalar ve sinir ađ ı modellerinin ç eřitli kombinasyonlarının performanslarını karřılařtırmıřlardır. Sonuçlar, başarısızlık tahmininde melez sinir ađ ı modellerinin diğ er modellere kıyasla daha iyi performansa sahip olduklarını göstermektedir.⁶⁵

Ç ok katmanlı sinir ađ larını kullanan Back ve diğ erleri (1998), sinir ađ larıyla birlikte girdi seçimi için genetik algoritmaların kullanımını önermektedirler. Onlar, modellerini iflastan üç yıl öncesine kadar olan verilere uygulamıřlar ve ç ok deđ iřkenli diskriminant analizi ve lojistik regresyon modellerine karřı önemli bir gelişme elde etmiřlerdir⁶⁶.

Tyree ve Long (1997), iřletme başarısızlıklarının tahmininde olasılıklı yapay sinir ađ ını kullanmıřlardır. Bu ç alıřmada, olasılıklı yapay sinir ađ ının hem geleneksel doğrusal diskriminant analizinden hem de geri yayılım sinir ađ larından daha yüksek performansa sahip olduđu görölmüřtür⁶⁷.

Shah ve Murtaza, iflas tahmini için daha kapsamlı bir yapay sinir ađ ı modeli geliştirilmesi gerektiđ ine inanarak 2000 yılında bir ç alıřma yapmıřlardır. Önceki ç alıřmalarla karřılařtırıldıđ ında, bu ç alıřmanın bazı ayırt edici özellikleri bulunmaktadır⁶⁸. Bunlar:

⁶⁴ Kimmo Kiviluoto; "Predicting Bankruptcies with The Self-Organizing Map", Neurocomputing, Vol. 21, 1998, pp. 191-201.

⁶⁵ Jaymeen R. Shah; Mirza B. Murtaza; "A Neural Network Based Clustering Procedure for Bankruptcy Prediction", American Business Review, June 2000, p.81.

⁶⁶ Atiya; a.g.e., p.931.

⁶⁷ Eric W. Tyree; J. A. Long; "Bankruptcy Prediction Models: Probabilistic Neural Networks Versus Discriminant Analysis and Backpropagation Neural Networks", City University, 1997, p.23.

⁶⁸ Shah; Murtaza; a.g.e., pp.80-81.

- Geçmişteki çalışmaların neredeyse tamamında, sadece bir yıla ait finansal oranlar kullanılırken, bu çalışmada işletmenin finansal gücü ve zayıflığıyla ilgili eğilimleri de dikkate almak için ağıın eğitiminde 3 yıla ait finansal oranlar kullanılmıştır.
- Geçmişteki çalışmaların çoğunda, ağıın eğitiminde geri yayılım tekniğı kullanılırken, bu çalışmada kümelemeye daha uygun olduğı düşünülerek denetimsiz öğrenme kullanılmıştır.
- Geçmiş çalışmaların hiçbirinde bulunmamasına rağmen bu çalışmada melez sinir ağı modeli kullanılmıştır.

Çalışmanın sonucunda elde edilen model, örneklem içi iflas etmiş ve etmemiş tüm işletmeleri % 73 oranında doğru olarak sınıflandırmıştır. Çapraz geçerlilik testi yapılmaması ve modelin doğruluğunun örneklem dışı işletmeler üzerinde test edilmemesi, çalışmanın en büyük eksikliğidir.

Geçmişteki çalışmalar incelendiğinde, yapay sinir ağı modellerinin diskriminant analizi, logit analizi gibi geleneksel istatistikî yöntemlerin üzerinde performans gösterdiği sonucu çıkarılabilir. Buna rağmen, hem çok değişkenli diskriminant analizi hem de lojistik regresyon analizi gerek uygulamada gerekse akademik çalışmalarda hala yaygın olarak kullanılmaktadır. Finansal başarısızlık tahmini için yapılan çalışmalarda söz konusu iki yöntemden hala önemli birer karşılaştırma aracı olarak yararlanılmaktadır.

Finansal başarısızlık tahmin alanında yapılan ampirik çalışmaların yanı sıra, tek amacı bu çalışmaları inceleyerek ayrıntılı bir literatür özeti sunmak olan bazı çalışmalar da bulunmaktadır. Bu çalışmalar burada belirtilmiştir.

Altman ve Narayanan, 1997 yılında yayınlanan makalelerinde finansal başarısızlık alanında 21 farklı ülkede yapılmış olan çalışmaları ayrıntılı bir şekilde incelemişlerdir⁶⁹. O'Leary ise 1998 yılında yaptığı çalışmada finansal başarısızlık tahmini alanında yapılmış 15 çalışmanın ayrıntılı bir karşılaştırmasını yapmıştır⁷⁰. Aziz ve Dar, 2004

⁶⁹ Edward I. Altman and Paul Narayanan; "An International Survey of Business Failure Classification Models", Financial Markets, Institutions&Instruments, Vol. 6, No. 2, 1997, pp.1-57.

⁷⁰ Daniel E. O'Leary; "Using Neural Networks to Predict Corporate Failure", International Journal of Intelligent Systems in Accounting, Finance & Management, Vol. 7, 1998, pp.187-197.

yılında sundukları bildiride, finansal başarısızlık alanında yapılmış ampirik uygulamaların bir analizini sunmuşlardır⁷¹. Kumar ve Ravi 2007 yılında yayınlanan çalışmalarında 1968-2005 yılları arasında finansal başarısızlık tahmini alanında yapılmış 128 çalışmayı inceleyen kapsamlı bir meta analizi yapmışlardır⁷².

⁷¹ M. Adnan Aziz and Humayon A. Dar; “Predicting Corporate Bankruptcy: Whither do We Stand?” (3rd Annual Meeting of the European Economics and Finance Society “World Economy and European Integration”), University of Gdansk, 13-16 May 2004, 51p.

⁷² Kumar, P. Ravi and V. Ravi; “Bankruptcy Prediction in Banks and Firms via Statistical and Intelligent Techniques – A Review”, European Journal of Operational Research, Vol.180, 2007, pp.1-28

İKİNCİ BÖLÜM: FİNANSAL BAŞARISIZLIK TAHMİNİNDE KULLANILAN YÖNTEMLER VE METODOLOJİK SORUNLAR

2.1. FİNANSAL BAŞARISIZLIK TAHMİNİNDE KULLANILAN YÖNTEMLER

Bugüne kadar yapılan finansal başarısızlık tahmin girişimleri, esas olarak işletme başarısızlığının muhtemel belirtileri olarak bilanço ve gelir tablosu bilgilerini kullanmışlardır. Girişimlerden bir kısmı ise işletme başarısızlığının nedenlerine bakarak modeller geliştirmişlerdir. Her iki araştırma türü de, pek çok tahmin metodu ve modeliyle sonuçlanmıştır. 1968 yılından önce tek değişkenli tarzda oluşturulan modeller hariç, neredeyse tüm modeller çok değişkenli tarzda işletme başarısızlığını tahmin etmeyi amaçlamaktadır.

Bu bölümde, finansal başarısızlık tahmin modelleri; 1) teorik modeller 2) istatistiki ve matematiksel modeller ve 3) yapay zeka modelleri olmak üzere üç ana kategoriye bölünerek, model oluşturmada izlenen yöntemler incelenmiştir. Yukarıdaki kategorilerden ilkinde başarısızlığın nedenleri dikkate alınırken, diğer ikisinde başarısızlığın belirtilerine bakılmaktadır⁷³.

Bu çalışmanın amacı ve kapsamı gereği, istatistiki ve matematiksel modellerle, yapay zeka tekniklerinden biri olan yapay sinir ağları daha geniş şekilde ele alınacaktır. Bununla birlikte, genel hatlarıyla teorik modeller hakkında da kısa bilgi verilecektir.

2.1.1. Teorik Modeller

İstatistiksel modellerin ve yapay zeka modellerinin odak noktası, işletme başarısızlığının nedenlerinden ziyade, başarısızlığın belirtileridir. Söz konusu modeller, işletmedeki mevcut göstergeleri inceleyerek işletme başarısızlığını tahmin

⁷³ Humayon; Dar; a.g.e., p.5.

edebilmektedirler. Bununla birlikte, başarısızlık tahmin problemine yaklaşımın diğerk bir şekli de, işletmeleri başarısızlığa zorlayan faktörleri dikkate almaktır. Bu yaklaşım altında, tahmin modelleri bir takım teorik argümanlara dayalı olarak kurulmaktadır. Finansal başarısızlık tahmininde kullanılan teorik modellerden bazıları aşağıda kısaca özetlenmektedir.

2.1.1.1. Bilanço Bozulma Ölçüsü/Entropi Teorisi

İşletmelerin finansal sıkıntılarını saptamanın bir yolu, bilançolarında meydana gelen değişiklikleri dikkatli bir şekilde incelemek olabilir. Bu teoriye göre, makul bir zaman içerisinde, bilanço yapısında önemli değişiklikler olmayan işletmenin, mevcut denge durumunu sürdürme eğiliminde olduğu, aksine bilanço yapısında önemli değişiklikler olan işletmenin ise mevcut denge durumunu muhafaza edemeyeceği kabul edilmektedir. Bilançodaki bu değişiklikler, büyük olasılıkla gelecekte kontrol altına alınamayacak türden olduğunda, söz konusu işletmelerin finansal açıdan başarısız olacakları tahmininde bulunmaktadır. Bilanço bozulma ölçüsü ya da entropi teorisinin argümanı bu temel mantığa dayanmaktadır⁷⁴.

2.1.1.2. Kumarbazın İflası Teorisi

Bu teorinin temel fikri, gelişigüzel miktarda parayla kumar oynayan bir kumarbazın oyunuyla ilişki kurmaktadır. Bir kumarbaz, belirli kazanç ve kayıp olasılıklarıyla kumar oynar. Oyun, kumarbaz tüm parasını kaybedene kadar devam eder.

Finansal başarısızlık tahmini bağlamında, işletmeler kumarbazın yerine konulmaktadır. İşletme, net değeri sıfır olana kadar faaliyetlerini devam ettirebilecektir. Teori, bir işletmenin, faaliyetlerine bağlı olarak nakit giriş ve çıkışlarına sahip olduğunu varsayar. Herhangi bir dönemde, işletme negatif ya da pozitif nakit akımına sahip olabilir. Üst üste birkaç dönem negatif nakit akımına sahip olması durumunda ise işletme iflas eder⁷⁵.

⁷⁴ A.g.e., p.18.

⁷⁵ A.g.e., p.19.

2.1.1.3. Nakit Yönetimi Teorisi

İşletmelerde kısa vadeli nakit yönetimi, önemli konulardan biridir. Nakit ya da fon akım tabloları, işletmenin nakit yönetimi fonksiyonunu raporlamaktadır. Nakit giriş ve çıkışları arasındaki uyumsuzluk, işletmenin nakit yönetimi fonksiyonunun başarısızlığı anlamına gelmektedir. Bu uyumsuzluğun belirli bir süre devam etmesi, işletmeyi finansal sıkıntıya ve iflasa götürebilecektir.

2.1.1.4. Felaket Teorisi ve Kaos Teorisi

İşletme başarısızlığını açıklamada felaket teorisini kullananlar, başarısızlığı bir felaket olarak ele almaktadırlar. Kaos teorisi ise işletmeleri karmaşık davranışlar gösteren, karmaşık sistemler olarak dikkate alır. Felaket ve kaos teorilerinin varsayımları yardımıyla finansal başarısızlığa teorik bir bakış açısı kazandırılmaktadır.

Teorik modeller hakkında bir fikir vermek amacıyla, yukarıda anlatılan teoriler dışında opsiyon fiyatlama teorisi, kredi riski teorisi gibi teoriler de finansal başarısızlık alanında kullanılmaktadır. Bu çalışmanın kapsamını, finansal başarısızlığın nedenleriyle ilgilenen teorik modellerden ziyade belirtileriyle ilgilenen ampirik modeller oluşturduğundan, daha fazla ayrıntıya inilmeye gerek duyulmamıştır.

2.1.2. İstatistiki ve Matematiksel Modeller

İşletmelerin başarısızlık riskini değerlendirebilmek, tahmin edebilmek ve işletmeleri finansal durumlarına göre sınıflandırabilmek için uygun bir model geliştirmeye yönelik çok sayıda çalışma bulunmaktadır. Bu çalışmalar, farklı temel varsayımlara ve farklı hesaplama karmaşıklıklarına sahip pek çok modelleme tekniği ve kestirim prosedürü kullanmışlardır. Bunlar arasında en popüler olanları; çok değişkenli diskriminant analizi ve lojistik regresyon analizi başta olmak üzere çeşitli istatistiki yöntemlerdir. Söz konusu modeller, belirli bir doğruluk derecesi veya yanlış sınıflandırma oranıyla, işletmeleri başarısız ve başarılı işletme gruplarına kategorize etmek için bir sınıflandırma prosedürü içermektedirler.

Finansal başarısızlık tahmini bağlamında ele alınarak, ayrıntılı bir şekilde anlatılacak olan istatistiki ve matematiksel yöntemler şunlardır:

- 1) Tek Değişkenli Analiz,
- 2) Risk İndeksi Modelleri,
- 3) Çok Değişkenli Diskriminant Analizi,
- 4) Koşullu Olasılık Modelleri (doğrusal olasılık modelleri, lojistik regresyon ve probit).

Söz konusu yöntemlerin temel özellikleri, spesifik varsayımları, avantajları ve dezavantajları hakkında bilgi verilecektir.

2.1.2.1. Tek Değişkenli Analiz

Beaver (1966)⁷⁶ yapmış olduğu çalışmayla, finansal oranları kullanarak işletme başarısızlık tahmin modeli geliştirmede öncü olmuştur. Beaver, işletmeleri başarısız olanlar ve başarılı olanlar şeklinde sınıflandırmada, en iyi değişkenleri tanımlayabilmek için ikili sınıflandırma testi uygulamıştır.

Tek değişkenli başarısızlık tahmin modelinin odak noktası, başarısızlığın bireysel sinyalleri üzerindedir. Her bir ölçü veya oran için ayrı bir sınıflandırma prosedürü kullanılmaktadır. Bir işletme sınıflandırılırken, her bir ölçü veya oranın değeri ayrı ayrı analiz edilmekte ve o orana karşılık gelen optimal kopuş değerine (yanlış sınıflandırma oranının minimum olduğu nokta) göre işletme başarısız veya başarılı şeklinde sınıflandırılmaktadır. Genellikle, işletmenin analiz edilen oranı kopuş değerinin altındaysa işletme başarısız, üzerindeyse başarılı şeklinde sınıflandırılır. Daha yüksek değer, daha zayıf finansal durumu işaret ettiği oranlar içinse tam tersi bir sınıflandırma kuralı uygulanır. Bu tür sınıflandırmanın doğruluğu, toplam yanlış sınıflandırma oranı ile 1. tip hata (başarısız bir işletmeyi yanlış şekilde başarılı olarak sınıflandırmak) ve 2. tip hata (başarılı bir işletmeyi yanlış şekilde başarısız olarak sınıflandırmak) yüzdeleri tarafından ölçülebilir.

Tek değişkenli finansal başarısızlık tahmin modellerinin en önemli avantajı, uygulanmasının basit olmasıdır. Tek değişkenli bir modelin uygulanması, herhangi bir

⁷⁶ Beaver, a.g.e., pp.71-111.

istatistik bilgisi gerektirmemektedir. Her bir oran için işletmenin sahip olduğu değer, o oran için belirlenen kopuş değeriyle karşılaştırılarak sınıflandırma yapılmaktadır.

Diğer taraftan, tek değişkenli analizin birtakım dezavantajları da bulunmaktadır. Tek değişkenli analiz, sınıflandırmada dikkate alınan finansal oranla başarısızlık durumu arasında doğrusal bir ilişki olduğu varsayımına dayanmaktadır. Gerçek hayatta, bazı oranların başarısızlık durumlarıyla doğrusal olmayan bir ilişki gösterdiği dikkate alındığında, bu varsayımın sıklıkla ihlal edildiği açıktır. Sonuç olarak, tek değişkenli modelleme tekniği çoğu zaman uygun olmayan bir şekilde kullanılabilen ve elde edilen sonuçlar şüpheli olabilmektedir. Ayrıca tek değişkenli modeller çelişkili sonuçlar üretebilmektedirler. Örneğin, bir işletme belirli bir oran için başarılı olarak sınıflandırılırken, diğer bir oran için başarısız olarak sınıflandırılabilir. Literatürde bu soruna tutarsızlık problemi denilmektedir. Tek değişkenli analiz için yapılan bir diğer eleştiri de, söz konusu modellerin, bir işletmenin durumunun tek bir değişkenle analiz edilemeyecek kadar karmaşık ve çok boyutlu bir kavram olduğu gerçeğiyle çelişmesidir. Ayrıca, tek değişkenli modellerde, finansal oranlar için optimal kopuş değerleri geriye dönük (expost; örnekteki işletmelerin gerçek başarısızlık durumunun bilindiği olay sonrası durum) olarak ve deneme yanılma esasına göre seçilmektedir. Bu nedenle, kopuş değerleri örneğe özgü olabilir ve tek değişkenli model, tahmin bağlamında (exante, işletmelerin gerçek durumlarının bilinmediği olay öncesi durum) kullanıldığı zaman sınıflandırma doğruluğu önemli ölçüde azalabilir. Son olarak, tek değişkenli analiz 1. tip ve 2. tip hataların göreceli maliyetlerini hesaba katmamaktadır. Beaver'in çalışmasında, bu maliyetler dolaylı olarak eşit varsayılmıştır⁷⁷.

⁷⁷ Argyris Argyrou; Predicting Financial Distress Using Neural Networks: Another Episode to the Serial?, Master of Science Thesis, HANKEN - Swedish School of Economics and Business Administration, Department of Accounting, 2006, p.11.

2.1.2.2. Risk İndeksi Modelleri

Beaver'in tek deęişkenli modeline karşılık, Tamari (1966)⁷⁸ bir çalıřma yapmıřtır. Çalıřmada, bir iřletmenin finansal durumunun tek bir orana dayanılarak deęerlendirilmesinin yetersiz kalacaęı ve tutarsızlık probleminden dolayı iřletmenin durumu hakkında kesin bir kaniya varılamayacaęı ileri sürülmüřtür. Buna dayanarak Tamari, bir risk indeksi geliřtirmiřtir. Risk indeksi, finansal durumun ölçüleri olarak genel kabul görmüř, farklı oranları içeren basit bir sistemdir. İndekste yer alan finansal oranlar dikkate alınarak, her bir iřletme için 0–100 arasında bir puan tespit edilir. Daha yüksek puan, daha iyi finansal durumu iřaret etmektedir. Ayrıca risk indeksi, bazı oranların dięerlerinden daha önemli olduęu gerçeęini hesaba katarak, önemli oranlara toplam puan içerisinde daha yüksek aęırlıklar tahsis etmektedir.

Moses ve Liao (1987)⁷⁹, risk indeksinin farklı bir türünü sunmuřlardır. Bu risk indeksi türü, ilk olarak, modelde kullanılan finansal oranların her biri için optimal bir kopuř deęeri saptamayı saęlayan, tek deęişkenli bir analiz gerektirmektedir. Daha sonra, her bir oran için ikili deęişken yaratılarak, bir iřletmenin oranı optimal kopuř deęerini ařtıęında söz konusu deęişkene "1", aksi durumda ise "0" deęeri atanmaktadır. Son olarak, elde edilen bu deęerler basit bir řekilde toplanarak bir risk indeksi elde edilmektedir. Aynen Tamari'nin modelinde olduęu gibi, bu risk indeksinin daha yüksek bir skora sahip olması, daha iyi bir finansal durumu göstermektedir.

Risk indeksi modellerinin en önemli avantajı, uygulanmasının basit olmasıdır. Buna karşılık, risk indeksi modellerinde yer alan deęişkenlere atanan aęırlıkların öznel olarak saptanması, söz konusu modellerin temel dezavantajını oluřturmaktadır.

2.1.2.3. Çok Deęişkenli Diskriminant Analizi

1968 yılında Altman, finansal başarısızlık tahmini alanında ilk kez çok deęişkenli bir istatistiki analiz teknięi kullanarak, Z skor denilen bir model geliřtirmiřtir. Altman'ın

⁷⁸ M. Tamari; "Financial Ratios as a Means of Forecasting Bankruptcy", Management International Review, Vol. 4, Winter 1966, pp.15-21.

⁷⁹ D. O. Moses; S. S. Liao; "On Developings Model for Failure Prediction", Journal of Commercial Bank Lending, 1987, Vol. 69, pp.27-38.

kullandığı yöntem, çok değişkenli diskriminant analizidir. Yıllar boyunca, Altman'ın Z skor modelini esas alan pek çok çalışma yapılmıştır. Altman ve diğerleri, 1977 yılında yaptıkları çalışmayla orijinal Z skor modelini yeniden düzenleyerek daha iyi performansa sahip Zeta modelini oluşturmuşlardır.

Çok değişkenli diskriminant analizi; bir gözlemi, gözlemin bireysel özelliklerine dayanarak, çeşitli önsel gruplardan birine sınıflandırmada kullanılan istatistiksel bir tekniktir. Çok değişkenli diskriminant analizi, gruplar arasında en iyi ayrımı yapan özelliklerin, doğrusal veya kuadratik bir bileşimini türetmeye çalışmaktadır.

1980'li yıllara kadar, çok değişkenli diskriminant analizi tekniği, finansal başarısızlık tahmini literatürüne hakim olmuştur. 1980'lerden sonra, çok değişkenli diskriminant analizi daha az kullanılmakla birlikte, karşılaştırmalı çalışmalarda bir mihenk taşı olarak sıklıkla kullanılmaya devam etmiştir. Diğer bir ifadeyle, çok değişkenli diskriminant analizi, finansal başarısızlık tahmini alanında genel kabul görmüş standart bir metod olma özelliğine sahiptir. Söz konusu metodu kullanan çalışmaların çoğunda, doğrusal çok değişkenli diskriminant analizi yöntemi kullanılırken, bazı çalışmalarda eşit olmayan ayrılma matrisleri probleminin üstesinden gelebilmek için kuadratik çok değişkenli diskriminant analizi de kullanılmıştır.

Doğrusal çok değişkenli diskriminant analizi ile geliştirilen bir model, başarısız ve başarılı gruplar arasında en iyi ayrımı sağlayan değişkenlerin doğrusal bir bileşimidir. Doğrusal diskriminant fonksiyonu aşağıda gösterilmektedir:

$$Z_i = \beta_0 + \beta_1 X_{i1} + \beta_2 X_{i2} + \dots + \beta_n X_{in}$$

Burada;

Z_i ; i işletmesi için diskriminant skoru ($-\infty$ ve $+\infty$ arasında),

β_0 ; sabit terim,

β_j ; doğrusal diskriminant katsayıları ($j = 0, 1, \dots, n$),

X_{ij} ; i işletmesi için X_j özelliğinin değeri ($j = 1, 2, \dots, n$).

Çok değişkenli diskriminant modelinde, bir işletmenin çeşitli özellikleri (çoğunlukla finansal özellikleri), tek bir diskriminant skorunda birleştirilmektedir. Bu diskriminant skoru, $-\infty$ ve $+\infty$ arasında bir değere sahip ve işletmenin finansal durumunun bir göstergesi olan tek boyutlu bir ölçüdür. Çoğu çalışmada, düşük diskriminant skoru finansal sağlığın zayıf olduğunu göstermektedir. Çeşitli değişkenlerin tek bir performans ölçüsü haline dönüştürülmesi, yani bir diskriminant skorunda birleştirilmesi, başarısızlığın tahmini bağlamında önemli yararlar sağlamaktadır. Tek değişkenli analizde önemsiz olarak bulunan veya sezgisel olarak önemsiz olduğu düşünülen bazı değişkenler, kimi zaman çok değişkenli bağlamda önemli bilgiler arz edebilmektedir.

Sınıflandırma bağlamında, çok değişkenli diskriminant analizinin esası, diskriminant skoruna dayanarak bir işletmeyi başarısız veya başarılı gruplardan birine atamaktır. Sınıflandırma, çok değişkenli diskriminant modeli için belirlenen bir kopuş değerine göre gerçekleştirilmektedir. Bir işletmenin diskriminant skoru (Z), kopuş değerinden daha küçükse o işletme başarısız gruba, diğer durumlarda ise yani diskriminant skoru kopuş değerine eşit ya da daha büyük olduğunda başarılı gruba sınıflandırılmaktadır. Kimi diskriminant modellerinde tam tersi bir durum söz konusudur. Diskriminant skoru kopuş değerinden küçük olduğunda işletme başarılı olarak, tersi durumda ise başarısız olarak sınıflandırılır.

Çok değişkenli diskriminant modellerinin sınıflandırma doğruluğu veya performansı, genellikle 1. tip (başarısız işletmeleri başarılı olarak yanlış sınıflandırma) ve 2. tip hata (başarılı işletmeleri başarısız olarak yanlış sınıflandırma) oranlarına dayanılarak değerlendirilmektedir. Ayrıca, toplam doğru sınıflandırma yüzdesi veya ağırlıksız hata oranı da sık sık kullanılmaktadır. Belirli bir kopuş değerinin saptanmasını gerektiren bu ölçülerden başka, çok değişkenli diskriminant modellerinin performansı daha anlamlı ölçüler kullanılarak da değerlendirilmektedir. Bu hususta, bir kopuş değerinin belirlenmesini gerektirmeyen ROC eğrisi ve değişim fonksiyonu, bir modelin performansının grafiksel gösterimini sağlamaktadır. ROC altında kalan alanın geniş olması veya değişim fonksiyonunun her iki eksene yaklaşması, modelin performansının daha iyi olduğu anlamına gelmektedir. Örnek verilerine dayalı olarak elde edilen doğru sınıflandırma yüzdesi, sınıflandırma prosedürünün gücünü olduğundan daha fazla gösterebilir. Buna karşı alınabilecek önlemlerden biri, modelin üzerinde kurulduğu örnekten farklı başka bir örnek üzerinde modeli test etmektir. Bunun için örnek, tesadüfi

olarak iki alt kümeye bölünebilir, bu alt kümelerden biri diskriminant fonksiyonu türetmede kullanılırken, diğeri test için kullanılır.

Çok deęişkenli diskriminant analizi, çeşitli varsayımlara dayanmaktadır. Analizin ayırım gücü, söz konusu varsayımların sağlanmasına ya da bu varsayımlara karşı analizin sağlam olmasına bağlıdır. Yapılan çalışmalarda, genellikle modelin performansı yüksek çıktığında, bu varsayımların sağlanıp sağlanmadığı hususu göz ardı edilmektedir. Bununla birlikte, özellikle modelin performansı beklenenden düşük olduğunda, doğru yorumda bulunabilmek için bu varsayımların test edilmesinin gerekli olduğu düşünülmektedir. Diskriminant analizinin varsayımları aşağıda yer almaktadır:

- 1) Birbirinden kesin olarak ayrılabilen iki ya da daha fazla grup bulunmaktadır,
- 2) Veriler tesadüfi olarak seçilmiştir,
- 3) Modelde kapsanan deęişkenler, çok deęişkenli normal dağılıma sahiptir,
- 4) Başarısız ve başarılı gruplar arasındaki grup ayrılma matrisleri veya varyans-kovaryans matrisleri eşittir,
- 5) Başarısızlığın önsel olasılığı ve yanlış sınıflandırma maliyetleri bilinmektedir.

Bazı araştırmacılar, özellikle çok deęişkenli normal dağılım ve ayrılma matrislerinin eşitliği sınırlayıcı varsayımlarının önemini ve neden olabilecekleri yanlışlığı vurgulamışlardır. Buna rağmen, çoğu finansal başarısızlık tahmini çalışmasında bu varsayımların karşılanıp karşılanmadığı dikkate alınmamaktadır. İşletme verileri bu varsayımları nadir olarak karşıladığı için, çok deęişkenli analiz tekniği sıklıkla bu varsayımlar ihlal edilerek kullanılmaktadır.

Çok deęişkenli diskriminant analizi, finansal başarısızlık tahmininde en çok kullanılan modelleme tekniği olmasına rağmen, daha önce bahsedilen temel varsayımların ihlaliyle ilgili problemlerin dışında bazı dezavantajlara da sahiptir. İlk olarak, çok deęişkenli diskriminant analizi ile elde edilen sınıflandırma kuralı doğrusaldır. Yani, belirli bir kopuş deęerinin altındaki veya üzerindeki bir diskriminant skoru, işletmenin başarısız ya da başarılı olduğunu işaret etmektedir. Bu durum, bazı deęişkenlerle finansal durum arasında doğrusal bir ilişki bulunmadığı gerçeğiyle çelişmektedir. Öyle ki, bazı

değişkenler hem çok yüksek, hem de çok düşük olduklarında finansal problemleri gösterebilmektedir. İkinci bir husus, diskriminant skorları, işletmeler arasında sadece görel bir sıralamaya imkân tanıyan sıralama ölçüleridir. Diğer bir ifadeyle, diskriminant skorları finansal başarısızlık olasılığını göstermemektedirler. Üçüncü olarak, çok değişkenli diskriminant analizi, çoklu regresyon analizi tekniğine oldukça benzemesine rağmen, hesaplama açısından farklılıklar bulunmaktadır. Çok değişkenli diskriminant analizinde, bağımsız değişkenlerle ikili bağımlı değişkenler arasında bir ilişki kestirilirken en küçük kareler yöntemi uygun değildir. Bunun bir sonucu olarak, çok değişkenli diskriminant modelinin standardize edilmiş katsayıları, regresyon modelindeki β katsayıları gibi yorumlanamazlar ve farklı değişkenlerin görel önemini göstermezler⁸⁰.

2.1.2.4. Koşullu Olasılık Modelleri

Çok değişkenli diskriminant analizi, 1980'li yıllara kadar finansal başarısızlık tahmini alanına hakim olmuş ve bu yöntemi kullanan çok sayıda çalışma yapılmıştır. 1980'li yıllarda söz konusu yöntem, yerini logit analizi (lojistik regresyon analizi), probit analizi ve doğrusal olasılık modelleme tekniği gibi istatistiki tekniklere bırakmıştır. Koşullu olasılık modelleriyle sonuçlanan bu teknikler, başarısız ve başarılı işletme grupları arasında en iyi ayrımı yapan değişkenlerin bir birleşiminden oluşmaktadır.

Ohlson (1980)⁸¹, işletme başarısızlığını tahmin etmek için finansal oranlar üzerinde logit analizini kullanan ilk araştırmacıdır. Bu alanda probit analizinin kullanılmasına ise, 1984 yılında yaptığı çalışmasıyla Zmijewski öncülük etmiştir⁸². Logit analizi, finansal başarısızlık tahmini alanında oldukça popüler bir yöntem olarak görülmesine karşın, muhtemelen daha fazla hesaplama gerektirdiği için probit analizi kullanan çalışmaların sayısı oldukça azdır.

⁸⁰ Balcaen; Ooghe; a.g.e., p.13.

⁸¹ Ohlson, a.g.e., pp.109-131.

⁸² Mark E. Zmijewski; "Methodological Issues Related to the Estimation of Financial Distress Prediction Models", Journal of Accounting Research, Supplement to Vol. 22, 1984, pp.59-82.

Koşullu olasılık modelleri, doğrusal olmayan bir maksimum olasılık hesaplama prosedürü yardımıyla, bir işletmenin özelliklerine bağlı olarak başarısızlık olasılığını kestirmeye imkan tanımaktadır. Söz konusu modeller, olasılık dağılımıyla ilgili belirli bir varsayım gerektirirler. Logit modelleri lojistik dağılımı varsayım olarak kabul ederken, probit modelleri kümülatif normal dağılım varsayımına dayanmaktadır. Doğrusal olasılık modellerinde ise, değişkenler ile başarısızlık olasılığı arasında doğrusal bir ilişki bulunduğu varsayılmaktadır. Logit analizi, açık bir şekilde literatürdeki en popüler koşullu olasılık yöntemi olduğu için, bu çalışmada daha çok söz konusu teknik üzerinde yoğunlaşmaktadır.

Koşullu olasılık modelleri, en iyi performansı örnek sayısı çok olduğunda göstermektedirler. Bununla birlikte, başarısızlık tahmin çalışmalarında kullanılacak işletme sayısı genellikle bu modellerin optimum seçim yapmasını sağlayacak yeterlilikte değildir. Örnek sayısının az olmasının yanı sıra, hesaplamasının da bir dereceye kadar çok değişkenli diskriminant analizinden zor olması, uygulamada koşullu olasılık modellerinin kullanımını sınırlamaktadır.

Aşağıda koşullu olasılık modelleri anlatılmaktadır.

2.1.2.4.1. Doğrusal Olasılık Modeli

Doğrusal olasılık modelini daha iyi anlayabilmek için, ilk olarak aşağıdaki fonksiyon dikkate alınabilir:

$$Z_i = \beta_0 + \beta_1 X_{i1} + \beta_2 X_{i2} + \dots + \beta_n X_{in}$$

Burada,

Z_i ; doğrusal olasılık fonksiyonunu,

X_i ; bağımsız değişkenleri,

β_i ; değişken katsayılarını,

β_0 ; sabit terimi temsil etmektedir.

Eğer bir olay gerçekleşirse $Z_i = 1$, tersi durumda ise yani olay gerçekleşmezse $Z_i = 0$ olmaktadır.

Bağımsız değişkenlerin doğrusal bir fonksiyonu olarak, Z_i 'yi açıklayan bu tür modellere doğrusal olasılık modeli denilmektedir. Çünkü, verilen X_i için Z_i koşullu beklentisi, söz konusu X_i için olayın gerçekleşme koşullu olasılığı $P(Z_i = 1 \mid X_i)$ olarak yorumlanabilir. Böyle bir model en küçük kareler yöntemi kullanılarak kestirilebilir. Doğrusal olasılık modelleri, koşullu olasılığın “0” ve “1” arasında olmasını gerektirdiğinden Z_i değişkeni “0” ve “1” arasında bir olasılık dağılımı izlemektedir⁸³.

Doğrusal olasılık modelleri, finansal başarısızlık tahmini alanına uygulandığında, başarısız ve başarılı işletmeler arasında ayırım yapmak için bir kopuş değeri belirlenir. Bu kopuş değerinin belirlenmesinde kullanılan kriter, genellikle sınıflandırma hatalarını minimize etmektir. Doğrusal olasılık modelleri, işletmeler için performans skorları oluşturmada kullanılmaktadır. Bu performans skorları belirlenen kopuş değeriyle karşılaştırılarak, işletmeler başarısız ya da başarılı gruba sınıflandırılır. Alternatif olarak, elde edilen doğrusal olasılık modeli skorları, başarısızlık olasılıkları olarak da yorumlanabilir.

2.1.2.4.2. Lojistik Regresyon Analizi

Bağımlı değişkenin kesikli olduğu durumlarda (yani bir olay meydana gelebilir ya da gelemez veya örnek bir kategoriye ait olabilir ya da olamaz), logit modeli regresyon modelinin doğal tamamlayıcısıdır. Bir regresyon denkleminin bağımsız değişkenleri arasında böyle değişkenler olduğu zaman, (0,1) kukla değişkenleri kullanılarak problemin üstesinden gelinebilir. Fakat, bağımlı değişken bu türden olduğunda regresyon modeli bozulmaktadır. Böyle durumlarda, logit modeli hazır bir alternatif teşkil etmektedir⁸⁴. Lojistik regresyon analizi, normal dağılıma uymayan verilerden etkilenmeyen daha sağlam bir tekniktir⁸⁵.

⁸³ Aziz; Dar; a.g.e., p.7.

⁸⁴ Christian L. Dunis; J. Alexandros Triantafyllidis; “Alternative Forecasting Techniques for Predicting Company Insolvencies: The UK Example (1980-2001)”, Neural Network World, No. 3, 2003, p.13.

⁸⁵ Bullock; a.g.e., p.21.

Lojistik regresyon analizinde, ikili bağımlı değişken basit olarak özel bir olayın gerçekleşme ihtimalinin logaritmasıdır. Yani, lojistik regresyon analizinde grup üyeliğinin kendisini modellemek yerine, bir gruba ait olma ihtimaller oranının (odds ratio) logaritması modellenmeye çalışılmaktadır. İhtimalleri (odds) modellemek mümkün olmakla birlikte, ihtimallerin logaritmasını [$\ln(\text{Odds}) = \ln(P / (1-P))$] modellemek daha basittir⁸⁶.

Lojistik regresyon analizini bir örnekle açıklamak, konunun daha iyi anlaşılması açısından faydalı olacaktır. Finansal başarısızlık tahmini için düşünüldüğünde, bir işletmenin başarısız olma olasılığı P olsun. Bu durumda, işletmenin başarısız olmama olasılığı da 1-P olacaktır. Görüldüğü gibi, P ve 1-P birbirini tamamlayan iki olayın olasılıklarını temsil etmektedir. Bu durumda, bir işletmenin finansal olarak başarısız olma ihtimaller oranı (odds ratio) şu şekilde hesaplanmaktadır⁸⁷:

$$\text{Odds} = P / (1-P)$$

Bir işletmenin finansal olarak başarısız olma ihtimaller oranının doğal logaritması alınarak logit değişkeni hesaplanır:

$$\ln(\text{Odds}) = \ln(P / (1-P))$$

Lojistik regresyon, logit değişkenini tahmin etmektedir. Lojistik regresyon analizinde, doğrusal olmayan bir maksimum olasılık hesaplama prosedürü kullanılarak parametreler hesaplanmakta ve aşağıdaki gibi bir lojistik regresyon modeli elde edilmektedir.

$$\ln(\text{Odds}) = \ln(P / (1-P)) = Z_i = \beta_0 + \beta_1 X_{i1} + \beta_2 X_{i2} + \dots + \beta_n X_{in}$$

Yukardaki formülden hareketle:

$$(P / (1-P)) = e^{Z_i}$$

Buradan:

⁸⁶ Aziz; Dar; a.g.e., p.8.

⁸⁷ Argyrou; a.g.e., p.91.

$$P = e^{Z_i} / (1 + e^{Z_i})$$

Pay ve paydayı e^{Z_i} , ye böldüğümüzde:

$$P = 1 / (1 + e^{-Z_i}) \text{ elde edilir.}$$

Burada;

Z_i ; Lojistik regresyon fonksiyonu,

P ; Verilen özellikler vektörü için başarısızlık olasılığı,

β_j ; j özelliğinin katsayısı ($j = 1, 2, \dots, n$)

β_0 ; sabit,

X_{ij} ; i işletmesi için j özelliğinin değeri ($j = 1, 2, \dots, n$)

e ; doğal logaritma tabanı.

Lojistik regresyon analizi tekniğiyle elde edilen model, her bir işletmenin çeşitli özelliklerini, işletmenin başarısızlık olasılığını veya başarısızlığa karşı kırılabilirliğini gösteren çok değişkenli bir olasılık skorunda birleştirmektedir. Logit skoru da denilen başarısızlık olasılığı P , $[0,1]$ aralığında bir değere sahiptir. Z_i , $-\infty$ 'a yaklaştığında P "0" değerine; Z_i , $+\infty$ 'a yaklaştığında ise P "1" değerine sahip olmaktadır. Daha önce de bahsedildiği gibi lojistik regresyon analizinde, başarısızlık olasılığı P , lojistik dağılım izlemektedir.

Başarısızlık durumu "1" olarak kodlandığında, yüksek logit skoru yüksek başarısızlık olasılığını göstermektedir. Aksine, başarısızlık durumu "0" olarak kodlandığında ise düşük logit skoru, yüksek başarısızlık olasılığını gösterir. Sınıflandırma bağlamında, lojistik regresyon modelinin esası, logit skoruna ve belirli bir kopuş noktasına dayanarak işletmeleri başarısız veya başarılı gruplardan birine atamaktır. Başarısızlığın "1" olarak kodlandığı ve yüksek logit skorunun yüksek başarısızlık olasılığını gösterdiği durumda, eğer logit skoru kopuş değerinin üzerindeyse işletme başarısız gruba atanır. Logit skoru kopuş değerinden düşük veya kopuş değerine eşit olduğunda ise işletme başarılı gruba sınıflandırılmaktadır. Logit modeli, çok değişkenli diskriminant

modelinde olduğu gibi benzerlik prensibine dayanmaktadır, yani işletmeler en çok benzedikleri gruba atanmaktadır.

Aynen çok değişkenli diskriminant modellerinde olduğu gibi, bir logit modelinin sınıflandırma doğruluğu veya performansı da 1. tip ve 2. tip hata oranları, doğru sınıflandırma yüzdesi, ağırlıksız hata oranı, ROC gibi ölçüler esasında değerlendirilebilir.

Lojistik regresyon analizi, çok değişkenli diskriminant analizinin bazı sınırlayıcı varsayımlarını gerektirmemektedir. Ayrıca, lojistik regresyon analizi, eşleştirilmemiş örneklerle çalışmaya imkan tanımaktadır. Bu yönüyle, diskriminant analize kıyasla daha az kısıtlayıcı bir yöntem olarak düşünülebilir. Bununla birlikte, lojistik regresyon analizi iki temel varsayıma dayanmaktadır. Bunlardan birincisi, bağımlı değişkenin ikili olduğu varsayımdır. Diğer bir ifadeyle, gruplar kesikli, kesişmez ve tanımlanabilir. İkinci varsayım ise 1. tip ve 2. tip hata maliyetlerinin, optimal kopuş olasılığının belirlenmesinde dikkate alınması gerektiğidir. Yanlış sınıflandırma maliyetlerinin belirlenmesi, sübjektif bir mesele olduğundan uygulamada çoğu araştırmacılar toplam hata oranını minimize ederler ve dolaylı olarak 1. tip ve 2. tip hata maliyetlerinin eşit olduğunu varsayarlar⁸⁸.

Lojistik regresyon analizinin, diskriminant analizinden daha az varsayıma dayanması dışında başka avantajları da bulunmaktadır. Birincisi, lojistik regresyon modelinin çıktısı olan logit skoru, doğrudan doğruya şirketin başarısızlık olasılığını gösteren “0” ve “1” arasında bir skordur. İkincisi, lojistik regresyon modelinin katsayıları, başarısızlık olasılığının açıklanmasında her bir bağımsız değişkenin önemi olarak ayrı ayrı yorumlanabilir. Üçüncüsü, lojistik regresyon modelleri sürekli verilerden başka, kukla değişkenler olarak kategorik nitel değişkenlerin kullanılmasına da imkan tanımaktadır. Son olarak, lojistik regresyon fonksiyonunun doğrusal olmaması bu yöntemin cazip yönlerinden biridir⁸⁹.

⁸⁸ Balcaen; Ooghe; a.g.e., p.15.

⁸⁹ A.g.e., pp.15-16.

Yukarıda bahsedilen avantajlarının yanı sıra, lojistik regresyon analizinin çeşitli ciddi dezavantajları da bulunmaktadır. İlk olarak, lojistik regresyon analizi kullanılarak elde edilen modeller, çoklu bağıntı problemine aşırı derecede duyarlıdır. Bu nedenle, birbiriyle yüksek derecede ilişkili değişkenlerin modele dahil edilmesinden kaçınılmalıdır. Ancak, finansal başarısızlık tahmini alanındaki lojistik regresyon modelleri, genellikle aynı pay veya paydaya sahip dolayısıyla da birbiriyle yüksek derecede ilişkili finansal oranlara dayandığı için, çoklu bağıntı problemi ciddi boyutlara ulaşabilmektedir. Lojistik regresyon analizinin diğer bir dezavantajı ise eksik ve uç değerlere karşı çok duyarlı olmasıdır. Bundan dolayı, bazı durumlarda veri setinin eksik ve uç değerler için düzeltilmiş olması gerekebilmektedir⁹⁰.

2.1.2.4.3. Probit Modeli

Yukarıda anlatılan lojistik regresyon modelindeki formülde, lojistik dağılım yerine normal kümülatif dağılım fonksiyonu yerleştirilerek probit modeli elde edilmektedir. Probit analizine ilişkin yorumlama esasları ve diğer hususlar lojistik regresyon analizinde anlatılanlarla aynıdır. Uygulamada probit analizi yerine genellikle lojistik regresyon analizi tercih edilmektedir. Bunun tek sebebi, lojistik regresyon analizinin probit analizine göre olan pratik kolaylığıdır.

2.1.3. Yapay Zeka Modelleri

Başlangıçta sadece sayısal işlemleri yapan makineler olarak dikkate alınan bilgisayarların, daha sonra problem çözme gibi insanların kavramaya yönelik faaliyetlerini sergileyecek şekilde sembolleri işleyebileceğinin farkına varılmıştır. Bu durum, insanların kavrama yeteneklerini taklit edebilen programlar konusundaki araştırmaları tetiklemiştir. Böylece, 1950'lerde söz konusu programların tasarımı ve uygulanmasıyla ilgili bilgiler ortaya çıkmaya başlamıştır. İnsan zekasını taklit etmeye yönelik çeşitli donanımlar ve yazılımlar ortaya çıkmıştır. Bu tür sistemlere yapay zeka denilmektedir⁹¹.

⁹⁰ A.g.e., p.16.

⁹¹ Aziz; Dar; a.g.e., p.12.

İnsanlar zekalarını, beyinlerinde bulunan bilgiye dayalı muhakeme yaparak problem çözmeye kullanabilmektedirler. Bundan dolayı bilgi, insan zekasında çok önemli bir rol oynamaktadır. Yapay zeka, insan zekasından esinlenerek ortaya çıkarıldığı için, muhakeme yoluyla problem çözümünde de benzer şekilde bilgiden yararlanılması gerekmektedir. Dolayısıyla, yapay zeka sistemlerinin en temel özellikleri, problem çözümünde bilgiye dayalı olarak karar verme özelliklerinin olması ve bu bilgilerden öğrendiklerini sonraki problemlere uygulayabilmesidir⁹².

Yıllar boyunca insan zekasını taklit etmeye yönelik olarak yapılan çalışmalar; uzman sistemler, bulanık mantık ve yapay sinir ağları gibi çeşitli yapay zeka yöntemleriyle sonuçlanmıştır. Yapay zeka yöntemleri, finansal başarısızlık tahminini de kapsayan çeşitli alanlardaki problemleri çözmeye başarılı şekilde kullanılmaktadır. Söz konusu yöntemlerden en önemlisi olarak görülen ve bu çalışmadaki uygulamada da kullanılan yapay sinir ağları, genel hatlarıyla aşağıda anlatılmaktadır.

2.1.3.1. Yapay Sinir Ağı Yaklaşımı

Yapay zeka yöntemlerinde, öğrenme çeşitli özel donanımlarda ya da çeşitli yazılımlar aracılığıyla bilgisayarlarda meydana gelmektedir. Bu nedenle, yapay zeka yöntemlerindeki öğrenmeye makine öğrenmesi denilmektedir. Makine öğrenmesinin bir çeşidi olan yapay sinir ağları, beyin faaliyetlerinin matematiksel modelleridir. Sinir ağlarının orijinal amacı, insanların bilgi işleme görevlerini araştırmak ve aynısını üretmektir. Son zamanlarda yapay sinir ağı metodolojisi; sınıflandırma, veri sıkıştırma, hile önleme, fonksiyon yaklaşım, pazarlama, tıbbi teşhis, optimizasyon, tabu eşleştirme ve sistem modelleme gibi alanlarda yaygın olarak uygulanmaktadır⁹³.

Geniş bir uygulama alanına sahip olan yapay sinir ağlarının en güçlü özelliği, verilerden ilişkileri öğrenebilme yetenekleridir. Bu nedenle, yapay sinir ağları kendilerinin dizayn edilmesinde kullanılan girdi verilerine bağımlıdır. Yapay sinir ağları, tahvil dereceleme, hisse senedi fiyat kalıplarının teşhisi, finansal sıkıntı teşhisi, kredi değerliliğinin belirlenmesi, banka başarısızlıklarının tahmini ve iflas tahmini gibi finansal alanlarda da

⁹² Ercan Öztemel; Yapay Sinir Ağları, Papatya Yayıncılık, İstanbul, 2003, s.13.

⁹³ Shah; Murtaza; a.g.e., p.81.

başarıyla kullanılmaktadır⁹⁴. Finansal başarısızlık tahmini alanında yapay sinir ağlarını kullanan çalışmalar, 1990 yılında başlamıştır ve halen yoğun şekilde devam etmektedir.

Bilgisayarlar sayısal hesaplamalarda, insan beyninden çok daha hızlıdır. Bununla birlikte insan beyni, bir bilgisayarda bulunması arzu edilen bazı yeteneklere sahiptir. Bunlar; özellikleri çabucak tanıma, verinin çok açık olmadığı durumlarda bile anlama ve yorumlama, geçmiş tecrübelerle dayanarak yargıda bulunma ve bunları daha önce hiç karşılaşılmamış olan durumlarla ilişkilendirme, çıkarsama yapma yetenekleridir. İnsan beyninin, sayılan görevleri yerine getirmede bilgisayarların çok ötesinde performans göstermesi, araştırmacıları insan beynini anlamaya ve modellemeye çalışmada motive etmiştir⁹⁵. Yapay sinir ağları, beyni taklit etmek suretiyle bilgisayarların bu eksikliklerinin üstesinden gelmeye çalışmaktadırlar⁹⁶.

Özellikle doğrusal olamaması ve parametrik olmaması, yapay sinir ağlarını, çok boyutlu veri setlerindeki karmaşık ilişkileri ortaya çıkarmada etkin bir yaklaşım yapmıştır. Yapay sinir ağları, ilişkilerin özelliğiyle ilgili herhangi önsel varsayımlar yapmayı gerektirmemektedir.

Yapay sinir ağlarının kavramsal temeli, insan beyninin sinirsel mimarisi üzerinde yapılan araştırmalara (Caudill; Rumelhart ve McClelland) dayanmaktadır. Yapay sinir ağları, tıpkı insan beyninde olduğu gibi, ağırlıklandırılmış yaylar (sinaps) aracılığıyla birbirleriyle bağlantılı ve katmanlar üzerinde düzenlenmiş sinir hücrelerinden (nöron) oluşmaktadır. Yapay sinir ağları terminolojisinde, sinir hücrelerine işlemci elemanlar ya da düğümler de denilmektedir. Düğümlerin bağlanma şekline ve ağırlıkların nasıl güncellendiğine bağlı olarak farklı yapay sinir ağı türleri bulunmaktadır. Birbiriyle bağlantılı yapı, çok katmanlı ileri beslemeli bir ağdaki gibi hiyerarşik olabilir. En düşük katmana giriş katmanı denirken, en son katman ise çıkış katmanı olarak bilinmektedir.

⁹⁴ Richard D. Gritta; Sergio Davalos; Marcus Wang et Al; "Forecasting Small Air Carrier Bankruptcies Using A Neural Network Approach: A Preliminary Analysis", Journal of Financial Management and Analysis, Vol. 13, No.1, January, 2000, p.45.

⁹⁵ Brad Warner; Misra Manavendra; "Understanding Neural Networks as Statistical Tools", The American Statistician, Vol:50, 1996, p.4.

⁹⁶ Kristen Bell DeTienne; David H. DeTienne and Shirish A. Joshi; "Neural Networks as Statistical Tools for Business Researchers", Organizational Research Methods, Vol.6, No.2, April 2003, p.237.

Bir ağda herhangi bir sayıda bulunabilen ve giriş katmanı ile çıkış katmanı arasında yer alan katmanlara ise orta ya da gizli katmanlar denilmektedir. Bir katmandaki sinir hücreleri (işlemci elemanlar), girdilerini bir sonraki katmandaki elemanlara doğru ileri beslerler. Sinir hücreleri arasındaki her bir bağlantı, kendisine eklenmiş olan bir ağırlığa sahiptir. Ağırlık, bir sinir hücresinin diğer sinir hücresi üzerindeki etkisinin derecesini gösterir. İşaretine bağlı olarak bir bağlantı, iki sinir hücresi arasındaki bağı güçlendirebilir veya zayıflatılabilir. Pozitif bir değer bağın güçlendirildiğini, tam tersine negatif bir değer ise zayıflatıldığını gösterir. Eğitim seti verileri giriş katmanına sunuldukça, yapay sinir ağı beklenen çıktı ve ağ çıktısı arasındaki hata minimize edilene kadar bağlantı ağırlıklarını ayarlar. Bu bağlantı ağırlıkları aracılığıyla ağ girdiyi ezberler⁹⁷. Ağırlıklar yapay sinir ağında depolanmış bilgiyi temsil etmektedirler. Bilginin ağı ağırlıkları şeklindeki bu dağıtılmış sunumu, hata toleransı, genelleme ve uyarlanma gibi yapay sinir ağlarının geleneksel modeller üzerindeki çeşitli avantajlarını ortaya çıkarır⁹⁸.

Yukardaki açıklamadan da anlaşılacağı üzere bir yapay sinir ağının temel hesaplama birimi sinir hücresidir. Sinir hücresi kavramı, insan beynindeki sinir hücrelerini taklit etme çabasıyla 1940 yılında McCulloch ve Pitts tarafından geliştirilmiştir. Bir yapay sinir ağında yer alan her bir sinir hücresi, sırasıyla şu görevleri yerine getirmektedir⁹⁹:

- Diğer sinir hücrelerinden sinyaller alınır (X_1, X_2, \dots, X_n).
- Sinyaller, sinir hücresinin ağırlıklarıyla çarpılır ($W_1X_1, W_2X_2, \dots, W_nX_n$).
- Ağırlıklandırılmış sinyaller toplanır (Toplam = $W_1X_1 + W_2X_2 + \dots + W_nX_n$)
- Hesaplanan toplam, aktivasyon fonksiyonu tarafından dönüşüme tabi tutulur [$F(\text{Toplam})$].
- Dönüştürülmüş toplam, diğer sinir hücrelerine gönderilir.

⁹⁷ Gritta; Davalos; Wang et Al; a.g.e., p.45.

⁹⁸ Ki-Dong Lee; Pattern Classification and Clustering Algorithms with Supervised and Unsupervised Neural Networks in Financial Applications, Doctorate Dissertation, Kent State University, 2001, p.15.

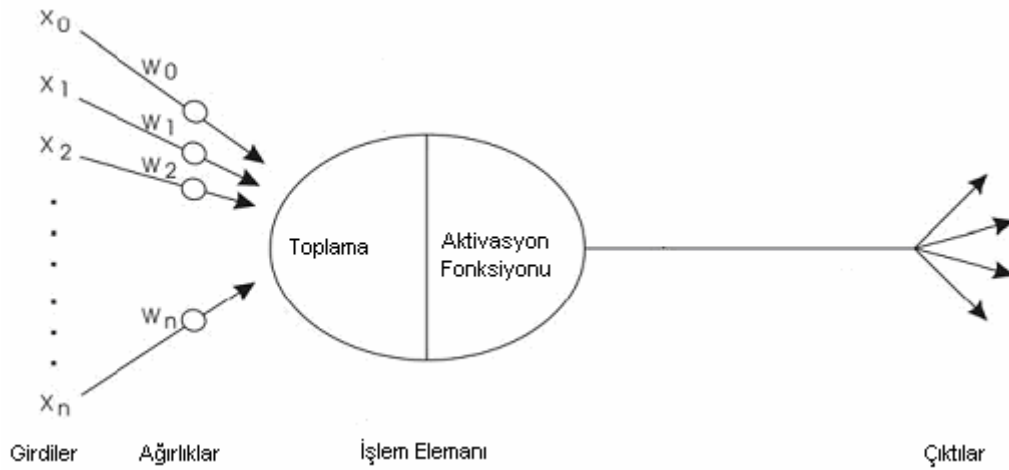
⁹⁹ DeTienne; DeTienne; Joshi; a.g.e., p.240.

Bir sinir hücresinin girdisi, kendisine bağlı sinir hücrelerinin çıktılarının ağırlıklı toplamıdır. Bunun için bir sinir hücresinin net girdisi:

$$\text{Net Girdi}_i = \sum_j W_{ij} \times \text{Çıktı}_j + \mu_i$$

Burada W_{ij} ; j sinir hücresini i sinir hücresine bağlayan ağırlıkları göstermektedir. Negatif bir ağırlık, sinir hücresinin çıktısının azalacağı anlamına gelirken, pozitif bir ağırlık sinir hücresini uyaracaktır. Çıktı_j , j düğümünün çıktısıdır. μ_i ise i düğümü için sabit bir değeri temsil etmektedir. Bu sabit değer, başka herhangi bir giriş olmaması durumunda bir sinir hücresine olan girdi değerini göstermektedir¹⁰⁰.

Bir sinir hücresinin işleyişi, Şekil 2.1. yardımıyla daha iyi anlaşılacaktır.



Şekil 2.1. Sinir Hücresinin Yapısı

Net girdinin hesaplanması, yapay sinir ağı analizinin özüdür. Hesaplanan girdiler toplamı, bir aktivasyon fonksiyonu kullanılmak suretiyle sinir hücresi tarafından çıktıya dönüştürülür. Aktivasyon fonksiyonu, genellikle net girdiyi sınırlı bir aralığa (sık sık $[0,1]$ veya $[-1,1]$) yerleştirir.

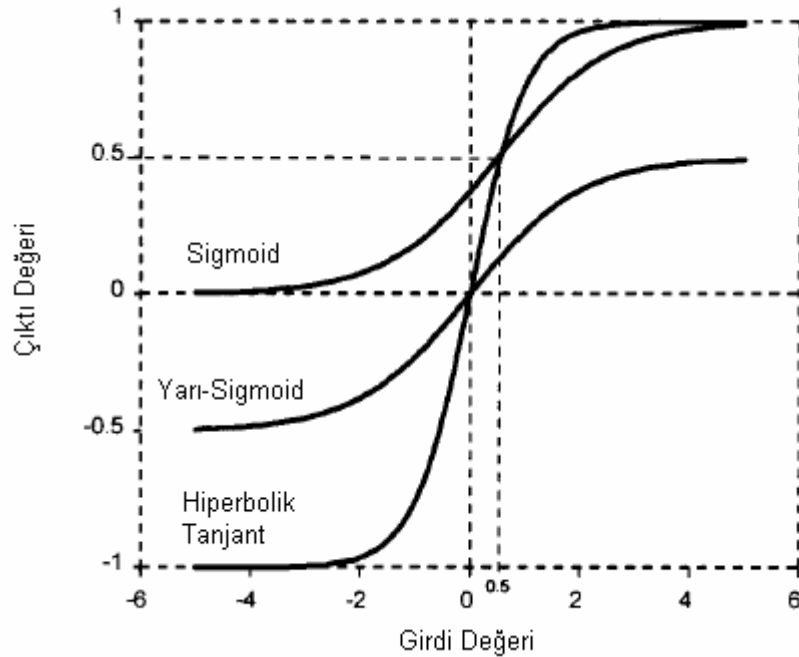
Aktivasyon fonksiyonuna bağlı olarak, yapay sinir ağları istatistiki metodlara benzeyebilir. Eğer aktivasyon fonksiyonu sürekli ve azalmayan bir fonksiyonsa, ağıın çıktı fonksiyonu doğrusal diskriminant fonksiyonuyla sonuçlanabilir. Aktivasyon

¹⁰⁰ A.g.e., p.240.

fonksiyonu, normal kümülatif dağılım fonksiyonu ya da lojistik kümülatif dağılım fonksiyonu olduğunda ise çıktı fonksiyonu logit ya da probit modeline benzer olacaktır¹⁰¹. Bu benzerlikler ilerleyen kısımlarda ayrıntılı olarak anlatılmaktadır.

Doğrusal aktivasyon fonksiyonları sadece doğrusal problemlerin çözümünde kullanılabilirler. Bu nedenle doğrusal olmayan fonksiyonların kullanımı, pek çok uygulama alanı için daha uygundur. Finans uygulamalarında çoğunlukla kullanılan doğrusal olmayan fonksiyon türleri, sigmoid (lojistik), yarı sigmoid ve hiperbolik tanjant fonksiyonudur.

Şekil 2.2.'de yapay sinir ağlarında yaygın olarak kullanılan aktivasyon fonksiyonları görülmektedir.



Şekil 2.2. Aktivasyon Fonksiyonları

Kaynak: James R. Coakley and Carol E. Brown; “Artificial Neural Networks in Accounting and Finance: Modeling Issues”, *Intelligent Systems in Accounting, Finance & Management*, Vol. 9, 2000, p.131.

¹⁰¹ Gritta; Davalos; Wang et Al; a.g.e., p.46.

Coakley ve diğerkleri, 1992 yılında yaptıkları çalışmada çok katmanlı ileri beslemeli geri yayılım ağı kullanarak üç transfer fonksiyonunun performanslarını ve yakınsama hızlarını karşılaştırmışlardır. Sonuç olarak, hiperbolik tanjant fonksiyonunun sigmoid ve yarı sigmoid fonksiyonundan hem daha çabuk yakınsadığını, hem de daha iyi performansa sahip olduğunu görmüşlerdir¹⁰².

Yukarıda anlatıldığı gibi, bir yapay sinir ağının ana görevi, farklı düğümler arasındaki bağlantılar için uygun ağırlıkları belirlemektir. Yapay sinir ağları bu görevlerini, belirli bir prensibi takip ederek, girdi ve çıktı sinyalleri arasındaki ilişki hakkındaki bilginin öğrenildiği bir eğitim süreci aracılığıyla yerine getirmektedirler. Söz konusu bilgi, nesnelere ait oldukları bilinen gruplara doğru olarak sınıflandıran bir düğümler yapısı ve bağlantı ağırlıkları yapısı üretmektedir. Bu eşleştirme sürecine teknik olarak yakınsama denilmektedir. Matematiksel bir teori izleyerek, sinir ağı daima yakınsayabilme yeteneğine sahiptir¹⁰³.

2.1.3.2. Yapay Sinir Ağlarının Avantajları

Yoğun derecede paralel işleyen yapısı ve öğrenme-genelleştirme yetenekleri, yapay sinir ağlarının en önemli özellikleridir. Genelleştirme, yapay sinir ağının eğitim (öğrenme) sürecinde karşılaşmadığı girdiler için mantıklı çıktılar üretebilmesi anlamına gelmektedir. Söz konusu iki yetenek, yapay sinir ağlarının kontrol edilmesi zor, karmaşık ve büyük ölçekli problemleri çözebilmesine imkan tanır¹⁰⁴. Yapay sinir ağlarının diğer yöntemlerde bulunmayan güçlü yanlarını şu şekilde sıralamak mümkündür¹⁰⁵:

- Tüm verilerin veya kuralların bilinmediği kirli ve eksik verileri tolere etme yeteneği,
- Kendi kendini organize etme ve ağ bağlantılarını değiştirerek öğrenme yeteneği,

¹⁰² James R. Coakley and Carol E. Brown; "Artificial Neural Networks in Accounting and Finance: Modeling Issues", Intelligent Systems in Accounting, Finance & Management, Vol. 9, 2000, p.131.

¹⁰³ Aziz; Dar; a.g.e., p.15.

¹⁰⁴ Simon Haykin; Neural Networks: A Comprehensive Foundation, Second Edition, Prentice Hall International Inc., 1999, p.2.

¹⁰⁵ Gritta; Davalos; Wang et Al; a.g.e., pp.4-5.

- Deneyimler tarafından eğitilme ve çevredeki değişikliklere dinamik olarak uyarlanma yeteneği,
- Belirli örneklerden genelleme yapabilme yeteneği,
- Girdi değişkenleri arasında karmaşık ilişkiler bulma ve kurma yeteneği,
- Paralel olarak verileri işleyebilme yeteneği,
- Verilerin dağılımı ya da faktörler arası ilişkilerin şekli hakkında varsayımlar gerektirmemesi.

Daha önce de belirtildiği gibi yapay sinir ağları, herhangi bir önsel fonksiyonel form varsayımına dayanmaz ve istatistiki sınıflandırma metodlarının gereksinim duyduğu varsayımların karşılanmasını gerektirmez. Diğer bir ifadeyle, yapay sinir ağı yaklaşımı sadece eldeki veriyle sınırlandırılarak yürütülebilir.

Bu güçlü yanları, yapay sinir ağlarının finansal başarısızlık tahmininde etkili bir araç olarak kullanılmasına destek sağlamaktadır.

2.1.3.3. Yapay Sinir Ağlarının Dezavantajları

Pek çok çalışmada, yapay sinir ağlarının yararlı olduğu savunulmasına karşın, söz konusu yöntemin de bazı dezavantajları bulunmaktadır. İlk olarak, problemin özelliklerine uygun bir yapay sinir ağı modeli oluşturmak kolay değildir. Çünkü farklı ağ mimarileri, öğrenme yöntemleri ve parametreler bulunmaktadır. Bunların belirlenmesinde en yaygın olarak kullanılan yöntem deneme-yanılmadır. Bu nedenle, uygun yapay sinir ağı yapısının tanımlanması için çok sayıda test yapılması gerekmektedir.

Yapay sinir ağları tarafından elde edilen nihai kurallar, kullanıcılar tarafından kavranılamazlar. Bu nedenle, yapay sinir ağları kara kutular olarak bilinmektedir. Son yıllarda, yapay sinir ağlarının bu kara kutu olma sorununu çözmeye yönelik birtakım çalışmalar yapılmıştır. Bu kapsamda, eğitilmiş ağlardan bilgi çıkarabilmek için geliştirilmiş algoritmalar bulunmaktadır. Söz konusu algoritmalar aracılığıyla çıkarılan bilgiler, “if (koşul), then (sonuç)” formunda sembolik kurallar olarak

açıklanabilmektedir. Fakat, çoğu problem için, eğitilmiş ağlardan elde edilen kuralların sayısı çok fazla olduğundan, kullanıcı için pratik bulunmamaktadır.

Bazı durumlarda, yapay sinir ağının karmaşık ilişkileri öğrenebilmesi için çok sayıda veriye gereksinim duyulmaktadır. Bu da, örnek sayısının az olduğu alanlarda yapay sinir ağı kullanımını zorlaştırmaktadır. Ayrıca, verilerin çok olması ve öğrenilecek ilişkinin fazla karmaşık olması durumunda yapay sinir ağlarının eğitilmesi uzun zaman alabilmektedir.

Yapay sinir ağları, spesifik eğitim örneklerine aşırı derecede duyarlı olduklarından, sonuçları güvenilmez olabilmektedir. Ağın eğitimi için kullanılan süreye bağlı olarak ya da diğer bir ifadeyle kullanılan iterasyon sayısına göre, aynı eğitim seti üzerindeki sonuçlar bile birbirinden çok farklı olabilmektedir. Eğitimin ne zaman durdurulması gerektiği konusunda çeşitli yöntemler bulunmakla birlikte, söz konusu yöntemlerin her zaman en iyi performansı sağlayacağı garanti değildir¹⁰⁶.

Yapay sinir ağları, anlamlılık testleri gibi bazı klasik istatistiksel özelliklerden yoksundur¹⁰⁷. Bu da, yapay sinir ağının değerlendirilmesini bazı durumlarda zorlaştırabilmektedir.

Yapay sinir ağları ile ilgili diğer iki önemli mesele, aşırı uygunluk ve yerel minimum problemleridir. Aşırı uygunluk, ağın bilgiyi öğrenmek yerine ezberlemesi olarak da bilinmektedir. Yapay sinir ağları alanında özellik arzeden diğer bir sorun ise, bazı ağ türlerinin genel optimuma ulaşmadan yerel bir minimumda tuzağa düşmesidir. Yapay sinir ağları açısından önemli görülen bu iki sorun, aşağıda ayrıntılı bir şekilde anlatılmaktadır.

¹⁰⁶ C. R. Krishnaswamy; Erika W. Gilbert; Mary M. Pashley; "Neural Network Applications in Finance: A Practical Introduction", Financial Practice and Education, 2000, p.82.

¹⁰⁷ Portia A. Cerny; "Data Mining and Neural Networks from A Commercial Perspective", the 36th Annual ORSNZ Conference, University of Canterbury, Christchurch, NZ, 2001, p.5.

2.1.3.3.1. Aşırı Uygunluk (Aşırı Öğrenme) Problemi

Bir yapay sinir ağının eğitilmesinde, ağın ne zaman durdurulacağını belirlemek önemlidir. Yapay sinir ağları eğitilirken, ağın çıktısı ile istenen çıktı arasındaki farkı minimize edebilmek için, eğitim kalıpları ve örnekler ağa tekrar tekrar sunulur. Örneklerin ağa sunulma sayısına devir denilmektedir. Normal olarak, devir sayısının fazla olmasının daha iyi olduğu düşünülür. Ancak, aynı eğitim kalıplarının ve örneklerin ağa tekrar tekrar sunulması ve bu suretle ağırlıkların, ağın çıktılarıyla istenen çıktıları birebir eşleştirecek şekilde ayarlanması durumunda, yapay sinir ağının ilişkilerin esasını kavramaktan ziyade kalıpları ezberlediği söylenebilir. Böyle bir durumda, ağın eğitilmesi esnasında kullanılan örnekler üzerinde son derece yüksek performans gösteren bir ağ, daha önce görmediği örneklerle karşılaştığı zaman iyi bir performans gösteremeyecektir. Diğer bir ifadeyle, ağın genelleştirme yeteneği bulunmayacaktır. Bu probleme aşırı uygunluk ya da aşırı öğrenme problemi denilmektedir¹⁰⁸.

2.1.3.3.2. Yerel Minimum Problemi

Yerel minimum problemi, yapay sinir ağının optimum (evrensel minimum) çözüm dışında yetersiz bir çözümde (yerel minima) sabitlenmesi anlamına gelmektedir. Ağların eğitiminde yaygın olarak kullanılan öğrenme algoritmalarından biri geri yayılım algoritmasıdır. Geri yayılım algoritması, daha sonra ayrıca anlatılacaktır. Burada, sigmoid aktivasyon fonksiyonu kullanan bir geri yayılım ağı için yerel minimum problemi aşağıda anlatılmaktadır¹⁰⁹:

- 1) Geri yayılım algoritması, ağın çıktısını istenen çıktıya yakınlatacak şekilde ağırlıkları değiştirir.
- 2) Sigmoid aktivasyon fonksiyonu, bir düğümün çıktısını 0-1 aralığında bir değere sıkıştırılmaktadır. “0” ve “1” noktaları sigmoid fonksiyonunun doyum noktalarıdır.

¹⁰⁸ Joseph B. Bigus; Data Mining with Neural Networks: Solving Business Problems from Application Development to Decision Support, McGraw Hill, 1996, p.94.

¹⁰⁹ Argyrou; a.g.e., pp.23-24.

- 3) Bir düğümün girdisi “0” ya da “1” e yaklaştıkça, sigmoid fonksiyonunun çıktısının ve türevinin çok küçük olacağı sonucu çıkarılabilir.
- 4) Ağırlıkların güncellenmesi, hata sinyali ve sigmoid fonksiyonu çıktısının türevi tarafından belirlendiği için ağırlık değişimi aşırı derecede küçük olur.
- 5) Ağın çıktısı, istenen çıktıya yaklaşmadan önce gizli katmanın tüm düğümleri doyum noktalarına (0 ve 1) yaklaşan bir çıktı ürettiği zaman bir uyumsuzluk ortaya çıkar. Ağın çıktısı henüz istenen çıktıya yaklaşmamasına rağmen, bundan sonra hiçbir ağırlık güncellenmez.
- 6) Hata sinyali geri yayılmaz ve girdi sinyali de ileri doğru akmaz. Böylece gizli katman, hiçbir işlevi yerine getiremez hale gelir ve ağ yerel minimumda tuzağa düşer.

2.1.3.4. Yapay Sinir Ağı Türleri

Yapay sinir ağları genellikle eğitim türüne göre iki gruba ayrılmaktadır; bunlar sırasıyla denetimli eğitim ve denetimsiz eğitimidir. Denetimli eğitim, girdi vektörleri ve buna karşılık gelen hedef vektörler olmak üzere eğitim çiflerine gereksinim duymaktadır. Denetimli eğitim oturumunda, her bir eğitim döngüsü (devir de denilen), yapay sinir ağı çıktı vektörleri ve hedef vektör arasındaki farkı hesaplar. Bu fark, denetimli ağ boyunca geriye beslenir ve buna göre ağın ağırlıkları ayarlanır. Bundan dolayı, denetimli bir ağın eğitim döngüsü yinelemeli bir hata azaltma sürecidir¹¹⁰.

Geriye yayılım ağı, denetimli öğrenme türünün en güzel örneğidir ve yapay sinir ağı literatüründe kullanılan en popüler eğitim metodudur. Denetimli eğitimin en önemli eksikliği, hedef vektörün bulunmadığı problemlerde uygulanamamasıdır. Tüm problemler için her zaman hedef vektörün bulunması mümkün olmadığından, bazı problemler için uygulanamaz.

Denetimsiz bir yapay sinir ağının üstünlüğü, bu eğitim türünün eşleştirilmiş eğitim vektörlerine gerek duymamasından kaynaklanmaktadır. Denetimsiz eğitim, sadece girdi vektörlerine ihtiyaç duymaktadır. Hedef vektörler gerekli değildir. Denetimsiz eğitim

¹¹⁰ Lee; a.g.e., p.5.

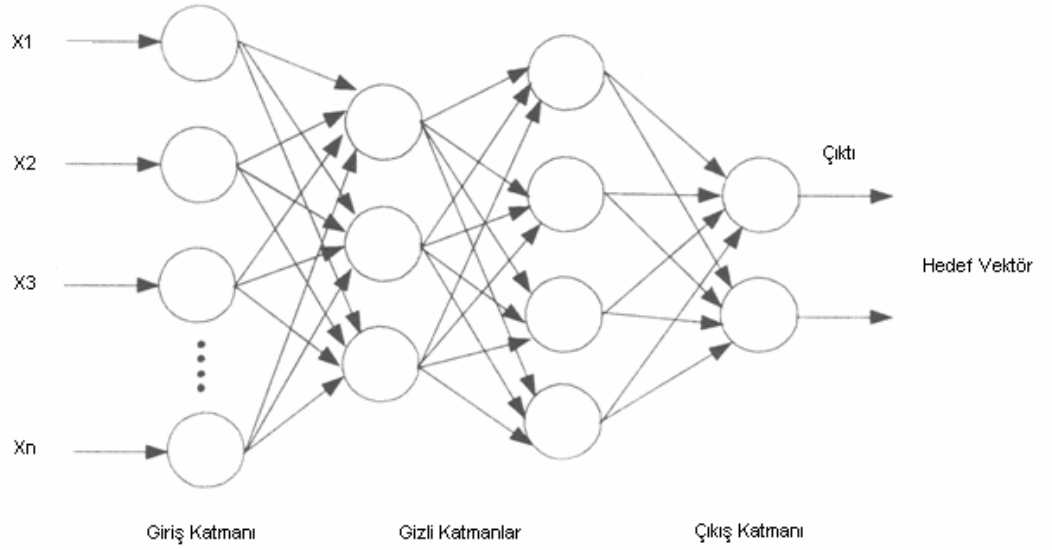
için geliştirilen algoritmalar, çeşitli formlarda çıktı vektörleri üretecek şekilde ağırlıklarını değiştirir. Herhangi bir hata hesaplamazlar, bu nedenle de denetimli eğitimdeki gibi bir hata ölçüsü ya da hata fonksiyonu yoktur. Denetimsiz eğitim süreci, girdi vektörlerini bazı benzer özelliklerine göre farklı çıktı sınıflarına veya kümelerine organize ederler. Denetimsiz öğrenmenin en iyi örneği Kohonen ağlarıdır. Denetimli ağlar, az sayıda da olsa finans alanında da kullanılmaktadır.

Eğitim türünden başka, yapay sinir ağları sinyal dönüştürme şekline göre de ileri beslemeli ve geri beslemeli olarak ikiye ayrılabilir. Geri beslemeli ağlarda, sinyaller ileri doğru gönderildiği gibi önceki katmanlardaki sinir hücrelerine doğru da gönderilir. Bu nedenle, geri beslemeli ağlar iki yönlü ağlar olarak da bilinmektedir. Genellikle bu tür ağlarda, sinyal transfer ilişkileri doğrusal değildir. Diğer taraftan, ileri beslemeli sistemlerde sinyaller sadece ileri doğru aktarılır.

2.1.3.5. Çok Katmanlı Perseptronlar ve Geri Yayılım Algoritması

Finansal başarısızlık tahmin çalışmalarında yaygın olarak kullanılan, bu çalışmada da tercih edilen ağ türü olan çok katmanlı perseptron ve geri yayılım öğrenme algoritması bu kısımda ayrıca anlatılmaktadır.

Perseptronlar, bir sinir ağının katmanlı konfigürasyonlarıdır. Perseptronun en basit formuna tek katmanlı perseptron ya da sadece perseptron denir. Tek katmanlı perseptron, sadece giriş ve çıkış katmanından oluşur. Giriş katmanı, sadece girdileri olarak bir sonraki katmana aktardığı ve başka bir işlem yapmadığı için genellikle katman sayısı belirtilirken hesaba katılmazlar. Çok katmanlı perseptronlar, giriş ve çıkış katmanı arasında gizli katman ya da katmanlara da sahiptir. Aşağıda yer alan Şekil 2.3.'de iki gizli katmana sahip çok katmanlı perseptron görülmektedir.



Şekil 2.3. Çok Katmanlı Perseptron

Geri yayılım algoritması, çok katmanlı perseptronlar için geliştirilmiş sistematik bir eğitim algoritmasıdır. Tipik bir geri yayılım eğitim süreci şu şekildedir: Düğümler, girdi değerlerini önceki düğümlerden ya da dışarıdan (giriş düğümlerinde olduğu gibi) alırlar. Alınan vektörlerin her biri, ilgili yayların ağırlıkları tarafından ağırlıklandırılır ve her bir düğümde toplanır. Sonra, ürünlerin toplamı, bir aktivasyon (transfer) fonksiyonu tarafından düğümün çıktısına dönüştürülür. Bu çıktı, sonraki katmandaki düğümlerin girdi değerini teşkil etmektedir. Çıktı katmanındaki çıktı değerleri hesaplanana kadar bu süreç devam eder. Daha sonra bu gerçek çıktı değerleri, hedef (istenen) değerlerle karşılaştırılarak aralarındaki fark (hata) hesaplanır¹¹¹.

Eğitim algoritması esas olarak, hataları minimize etmeye çalışan yinelemeli bir ağırlık ayarlama sürecidir. Geri yayılım, kavramsal olarak basit bir yinelemeli eğitim azaltma (iterative gradient descent) algoritmasıdır. Sinir ağları, daha önce de belirtildiği gibi, bağlantıların ağırlıklarını değiştirmek suretiyle öğrenmektedir. Eğitim aşaması boyunca, ağırlık çıktıları istenen çıktılarıyla karşılaştırılır. İki eşleştiği zaman, ağda herhangi bir değişiklik yapılmaz. Eğer istenen çıktıyla ağırlık çıktısı eşleşmezse hata terimi yaratılır. Bu hata ağ boyunca geri yayılır ve ağırlıklar buna göre ayarlanır.

¹¹¹ A.g.e., p.21.

İleri beslemeli bir ağı, geri yayılım algoritmasıyla eğitime süreci, basitleştirilmiş olarak aşağıda anlatılmaktadır¹¹²:

- 1) Girdi verileri ağa sunularak çıkış katmanına ulaşana kadar ağ boyunca yayılır. İleriye doğru gerçekleşen bu süreç hesaplanan çıktıyı üretir.
- 2) Hesaplanan çıktı, hedef çıktıyla karşılaştırılarak ağ için bir hata değeri hesaplanır.
- 3) Ağı eğitmek için, denetimli öğrenme algoritmalarından geri yayılım algoritması kullanılır. Bu algoritma, çıkış katmanı düğümleri ile en son gizli katman düğümleri arasındaki ağırlıklardan başlamak üzere ağ boyunca geriye doğru yayılır.
- 4) Geri yayılım bittiğinde, ileri doğru süreç tekrar başlar ve bu döngü hesaplanan çıktı ile hedef çıktı arasındaki hata minimize edilene kadar devam eder.

2.1.3.6. Yapay Sinir Ağının Modellenmesi

Genel bir yapay sinir ağı prosedürü, model kurma, eğitim ve test olmak üzere 3 aşamada özetlenebilir¹¹³:

Model kurma aşaması: Bu aşama, yapay sinir ağı mimarisinin belirlenmesini amaçlar. Bu aşamadaki temel görevler; girdi ve çıktı düğümlerinin sayısını, gizli katmanların ve gizli düğümlerinin sayısını ve düğümler arası bağlantıları belirlemeyi kapsar. Aktivasyon fonksiyonu, öğrenme oranı ve momentum gibi diğer parametreler de bu aşamada belirlenmelidir.

Finansal başarısızlık tahmini alanında kullanılan bir yapay sinir ağı, bağımsız değişken olarak kullanılacak finansal oran sayısı kadar girdi düğümüne ve başarılı/başarısız şeklindeki ikili sınıflandırmayı temsil eden tek düğümlü bir çıktı katmanına sahiptir.

Yapay sinir ağı mimarisinin belirlenmesi, ağıdaki gizli katmanların sayısını ve her bir katmanda yer alacak gizli düğümlerinin sayısının saptanmasını da gerektirir. Çok katmanlı ağların doğrusal olmayan modelleri temsil etme yeteneği, Kolmogorov

¹¹² Cerny; a.g.e., p.4.

¹¹³ Lee; a.g.e., pp.25-26.

tarafından ispatlanan bir teorem aracılığıyla 1963 yılında ortaya konulmuş ve 1990 yılında Hecht-Nielsen tarafından geri yayılım ağı için yeniden ifade edilmiştir. Bu genel teorem, daha sonra yapılan çalışmalarda da ileri beslemeli, çok katmanlı geri yayılım ağlarına uygulanmıştır. Teorem şu şekilde özetlenebilir¹¹⁴:

- Herhangi bir fonksiyon setini belirli bir doğruluğa yaklaştırmak için en fazla iki gizli katmana ihtiyaç vardır. Her bir gizli katmanda yeterli sayıda işlemci elemanın yer alması durumunda, istenen doğruluk elde edilebilir. Araştırmalar, istenen doğruluğu elde etmek için n girdili bir ağda, katman başına en fazla $2n + 1$ sayıda işlemci düğüm gerekeceğini öne sürmektedir.

- Herhangi bir sürekli fonksiyonu tek bir gizli katman kullanarak istenen doğrulukla yaklaştırmak mümkündür. Fazladan gizli katman eklemek, eğitim ve değerlendirme için işlem gereksinimini artıracığından zararlı görülmektedir. Bu nedenle istenen doğruluğu sağladığı takdirde tek gizli katmanlı mimari tercih edilmelidir.

- Bir ağdan iyi bir genelleştirme elde etmek için genel kural, veriyi uyduracak en küçük sistemi kullanmaktır. En küçük sistemi bulmak için literatürde çeşitli yöntemlerin kullanıldığı görülmektedir. En çok kullanılan yöntem ise deneme-yanılma yöntemidir.

Yapay sinir ağları sınıflandırma için kullanıldığında, gizli katmanda girdi katmanındakinden daha az sayıda düğüm bulunması gerektiği öne sürülmektedir. Çünkü bu durum, modeli veri sıkıştırılmaya zorlayacak ve esas bileşenleri yakalayacak ağırlıklar elde edilecektir¹¹⁵. Bu hususta genel kabul görmüş fikir şudur: gizli katmanda çok fazla düğüm bulunması girdi verilerini ezberleyen bir ağ üretecektir ve bu ağ genelleştirme yeteneğinden yoksun olacaktır. Gizli düğümlerin sayısı azaldıkça, eğitim örneğindeki sınıflandırma oranının azaldığını fakat test örneğindeki sınıflandırma oranının arttığını gösteren bulgular vardır. Diğer bir ifadeyle, gizli katmandaki düğümlerin sayısının artması, ağın eğitim seti dışındaki sınıflandırma yeteneğini azaltmaktadır¹¹⁶. Ancak unutulmamalıdır ki, gizli düğümlerin sayısının gerekenden az olması da ağın gerek eğitim seti ve gerek test seti üzerindeki sınıflandırma yeteneğini azaltacaktır.

¹¹⁴ Coakley; Brown; a.g.e., pp.133-134.

¹¹⁵ Lee; a.g.e., p.27.

¹¹⁶ Coakley; Brown; a.g.e., p.134.

Model kurma aşamasında belirlenmesi gereken diğer iki parametre de öğrenme oranı ve momentumdur. Her iki parametre de matematiksel sebeplerden dolayı 0-1 aralığında değerler almaktadır. Öğrenme oranı, öğrenmenin hızını belirler. Oran büyüdükçe, ağırlıklardaki değişim de daha büyük olur ve böylece ağ daha hızlı öğrenir. Bununla birlikte, öğrenme oranının çok büyük olması ağırlıkların yetersiz çözümler arasında salınmasına neden olur. Sonuç olarak amaç, ağırlıkların yetersiz çözümler arasında salınımlarına yol açmayacak olası en büyük öğrenme oranını kullanmaktır. Böyle bir oran, ağırlıkların optimum sürede en iyi öğrenmeyi başarmasını sağlayacaktır. Ayrıca, momentum terimi dahil ederek geri yayılım algoritmasını modifiye etmek mümkündür. Momentum terimi, ağırlıkların sadece aynı yönde değişmesini sağlayarak ağırlıkların salınımlardan kaçınmasına neden olur. Momentum terimi, yerel minimum problemlerden sakınmaya yardımcı bir parametredir¹¹⁷.

Eğitim aşaması: Bu aşamada veri setleri kullanılarak yayların ağırlıkları belirlenir. Eğitim aşamasında ilk olarak veri seti; eğitim ve test (veya geçerlilik) seti olmak üzere ikiye bölünür. Sonra eğitim seti kullanılarak hataların tekrarlamalı ayarlanması yöntemi aracılığıyla yayların ağırlıkları belirlenir. Eğer gerekirse, her bir girdinin ağırlıkta eşit muamele görmesini sağlamak amacıyla veriler normalleştirilebilir.

Ağın eğitimi, hata fonksiyonunu minimize edecek şekilde ağırlıklar setini ayarlamak için girdilerin ileri doğru işlenmesi sonucu elde edilen hatanın yayılmasını kapsar. Geri yayılım algoritması, devir sayısı arttıkça eğitim setindeki toplam hatanın azalacağını garanti eder. Her bir devirde, ağırlıklar hatayı azaltacak şekilde düzeltilir. Eğitim ilerledikçe, hata fonksiyonundaki değişim miktarı daha küçük olmaktadır. Hata fonksiyonundaki değişim belirlenmiş eşik değerden daha küçük olduğunda ise yakınsama vuku bulmaktadır¹¹⁸.

Bir ağı doğru derecede eğitmek son derece önemlidir. Eğitim sürecinde çok fazla ya da çok az iterasyon kullanımından sakınılmalıdır. Bir ağı hızlı şekilde eğitilmesi ile kalıpları doğru şekilde tanınması arasında bir değişim vardır. Gerekli iterasyon sayısı işlenecek kalıpların karmaşıklığına bağlıdır. Gerekinden az sayıda iterasyon, yetersiz

¹¹⁷ Argyrou; a.g.e., p.23.

¹¹⁸ Coakley; Brown; a.g.e., p.137.

bir eğitimle sonuçlanacaktır. Gerekenden fazla iterasyon ise ağıın eğitimi için gerekli süreyi uzatmakla kalmayacak, aşırı uygunluk problemine de neden olarak ağıın test seti üzerindeki performansını azaltacaktır¹¹⁹.

Test aşaması: Bu aşamada, eğitim sürecinde ağıın hiç görmediğı, bu nedenle ağıın genelleştirebilme yeteneğini test edebilen bir örnek seti üzerinde, daha önce eğitilmiş olan ağıın performansı değerlendirilmektedir. Modelin performansını ölçmek için farklı uygulamalarda farklı kriterlerin kullanılması mümkündür.

Daha önce de belirtildiğı gibi, bazı parametrelerin belirlenmesi kompleks bir karar verme süreci gerektirdiğı için bir yapay sinir ağıını modellemek basit değildir. Belirli bir problem için uygun ağı mimarisini bulmak, zaman alıcı ve kapsamlı bir tekraralama sürecidir. Fakat, yapay sinir ağıı esas olarak veri yönelimli bir yaklaşım olduğundan, ağı mimarisini büyük ölçüde kullanılan veri setinin niceliğı ve niteliğı belirlemektedir¹²⁰.

2.1.3.7. Yapay Sinir Ağı ve İstatistiksel Yöntemler

Bazı yapay sinir ağıı modelleri çok değışkenli doğrusal regresyon, lojistik regresyon, diskriminant analizi, temel bileşenler ve kümeleme analizi gibi istatistiki tekniklerle benzer ya da özdeşirler¹²¹. Bu çalışmada kullanılan istatistiki tekniklerle (diskriminant analizi ve lojistik regresyon analizi) yapay sinir ağılarının benzerlikleri aşağıda diyagramlar yardımıyla anlatılmaktadır.

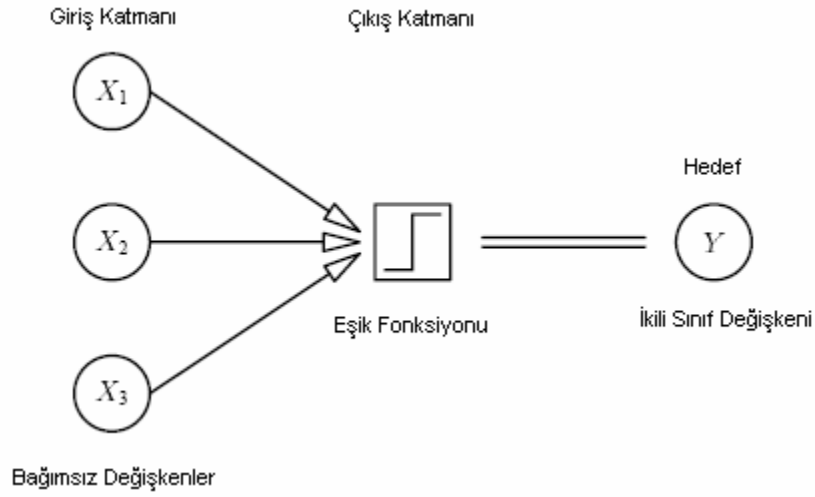
Doğrusal diskriminant analizi, aktivasyon fonksiyonu doğrusal olan tek katmanlı ve tek sinir hücreli perseptronun özel bir örneğı olarak görülebilir. Bu örnekteki sinaptik ağırlıkların değıerleri, doğrusal diskriminant analizi ile elde edilen fonksiyonun katsayılarıdır. Gerek bu örnek perseptron, gerekse doğrusal diskriminant analizi ile

¹¹⁹ C. R. Krishnaswamy; Erika W. Gilbert; Mary M. Pashley; “Neural Network Applications in Finance: A Practical Introduction”, Financial Practice and Education, 2000, p.78.

¹²⁰ Lee; a.g.e., p.26.

¹²¹ Warren S. Sarle; “Neural Networks and Statistical Models”, Proceedings of the Nineteenth Annual SAS Users Group International Conference, April, 1994, p.1.

kestirilen değerler birbirine eşit ya da oldukça benzerdir¹²². Doğrusal diskriminant analizine eşdeğer perseptron Şekil 2.4.'de görülmektedir.



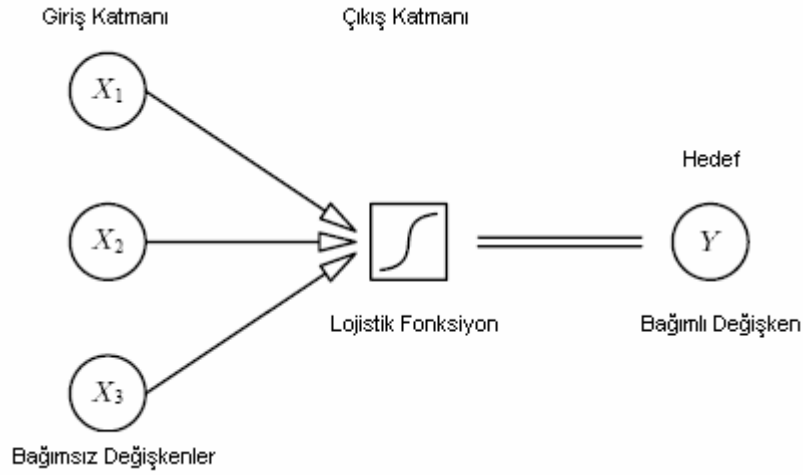
Şekil 2.4. Doğrusal Diskriminant Analizine Eşdeğer Perseptron

Kaynak: Warren S. Sarle; “Neural Networks and Statistical Models”, Proceedings of the Nineteenth Annual SAS Users Group International Conference, April, 1994, p.4.

Eğer transfer fonksiyonu Şekil 2.5.'de görüldüğü gibi standart lojistik fonksiyon olursa, perseptronun sonuçları lojistik regresyon tekniği tarafından elde edilen sonuçla çok benzer olacaktır¹²³.

¹²² Carlos Serrano-Cinca; “Feedforward Neural Networks in the Classification of Financial Information”, The European Journal of Finance, Vol.3, No.3, 1997, p.185.

¹²³ A.g.e., p.185.



Şekil 2.5. Lojistik Regresyon Analizine Eşdeğer Perseptron

Kaynak: Warren S. Sarle; “Neural Networks and Statistical Models”, Proceedings of the Nineteenth Annual SAS Users Group International Conference, April, 1994, p.3.

Yapay sinir ağı ve istatistiki modeller arasındaki temel fark, ağırlık değerlerinin belirlenmesi tarzıdır. Yapay sinir ağları, hata minimize edilene kadar ağırlıkları yinelemeli olarak ayarlayan dinamik bir programlama yaklaşımı kullanırken, istatistiki yöntemler ortalama hatayı minimize eden matematiksel bir yaklaşım kullanmaktadır¹²⁴.

2.1.3.8. Yapay Sinir Ağı Terminolojisi ve İstatistiksel Terminoloji

Bazı yapay sinir ağı modelleri, iyi bilinen istatistiki modellerle benzer ya da özdeş olmalarına rağmen, yapay sinir ağı literatüründeki terminoloji ile istatistiksel terminoloji arasında fark vardır. İki terminoloji arasındaki fark aşağıda Tablo 2.1.’de görülmektedir¹²⁵.

¹²⁴ Coakley; Brown; a.g.e., p.121.

¹²⁵ Anca Antanov; Performance of Modern Techniques for Rating Model Design, Master Thesis, Zürich, 2004, p.14; Sarle; a.g.e., p.2.

Tablo 2.1. İstatistiksel Terminoloji ve Yapay Sinir Ağı Terminolojisi Arasındaki Farklar

İstatistiksel Terminoloji	Yapay Sinir Ağı Terminolojisi
Değişkenler	Özellikler
Bağımsız Değişkenler	Girdiler
Kestirilen Değerler	Çıktılar
Bağımlı Değişkenler	Hedefler veya Eğitim Değerleri
Farklar	Hatalar
Kestirim	Eğitim, Öğrenme, Uyarlama veya Kendini Organize Etme
Kestirim Kriteri	Hata Fonksiyonu veya Maliyet Fonksiyonu
Gözlemler	Kalıplar veya Eğitim Çiftleri
Örnek	Eğitim Seti
Model Dışı Örnek	Test Seti
Parametre Kestirimleri	Sinaptik Ağırlıklar
Etkileşimler	Daha Yüksek Sıralı Sinir Hücreleri
Dönüşümler	Fonksiyonel Bağlar
Regresyon ve Diskriminant Analizi	Denetimli Öğrenme
Veri Azaltma	Denetimsiz Öğrenme
Kümeleme Analizi	Rekabetçi Öğrenme veya Uyarlamalı Vektör Niceleme
İnterpolasyon veya Ekstrapolasyon	Genelleme

2.2. FİNANSAL BAŞARISIZLIK TAHMİN ÇALIŞMALARINDA KARŞILAŞILAN METODOLOJİK SORUNLAR

Finansal başarısızlık tahmin çalışmalarında modellerin genelleştirilmesini sınırlayan veya sonuçların ihtiyatla karşılanmasına neden olabilecek bazı sorunlar bulunmaktadır. Bu sorunlardan bir kısmı, sadece bazı yöntemleri kullanan çalışmalara özgü sorunlar olmasına rağmen, bir kısmı tüm başarısızlık tahmin çalışmaları için ortaktır. Bu sorunlardan en önemlileri aşağıda anlatılmaktadır.

2.2.1. Örneklem Yöntemiyle İlgili Problemler

Bir finansal başarısızlık tahmin modeli, nihayetinde olay sonrası sınıflandırmadan ziyade başarısızlığın önceden tahmin edilmesi amacıyla kullanılacaktır. Bu nedenle, modelin oluşturulmasında kullanılan başarısız ve başarılı örneklerin, işletmelerin tüm popülasyonunu temsil edici nitelikte olması gerekmektedir. Üstelik, bazı istatistiksel yöntemler, tesadüfi örneklem varsayımına dayanmaktadır. Buna karşılık, geleneksel

istatistiki yöntemler kullanılarak oluşturulan tahmin modellerinin büyük çoğunluğunda, tesadüfi olmayan bir örnekleme kullanıldığı görülmektedir. Bunun sonucunda da örneğin bileşimi, popülasyonunkinden farklı olabilmektedir.

Eğer modelin oluşturulmasında kullanılan örnekler tesadüfi olarak belirlenmemişse, model parametrelerinin ve başarısızlık olasılıklarının taraflı olacağı ve sınıflandırma sonuçlarının da bu durumdan etkileneceği beklenebilir. Bazı araştırmacılar, tesadüfi olmayan örneklere dayanan başarısızlık tahmin modellerinde, elde edilen sınıflandırma doğruluğunun genelleştirilemeyeceğini ileri sürmektedir. Söz konusu araştırmacılar, modelin raporlanmış sınıflandırma doğruluğunun olay sonrası (expost) doğruluk olduğunu ve tahmin bağlamında modelin olay öncesi (exante) performansından çok farklı olabileceğini vurgulamaktadırlar. Diğer bir ifadeyle, modelin raporlanmış doğruluğu yanıltıcı olabilir¹²⁶. Bunun tam aksine, Zmijewski (1984) tesadüfi olmayan örneklerin kullanımının, toplam doğruluk oranlarını önemli derecede etkilemediğini bulmuştur¹²⁷.

Başarısızlık tahmin modelleri çoğu zaman sektör, büyüklük ve yaş gibi belirli karakteristikler dikkate alınarak belirlenen tesadüfi olmayan örnekler üzerinde oluşturulmaktadır. Bu durumda, bazı sektörler, büyüklük sınıfları ve yaş grupları örnek içerisinde yeterince temsil edilmemektedir. Bundan dolayı, modeller az temsil edilen bu işletme türlerinin başarısızlıklarını tahmin etmede etkin olmayabilir.

Tesadüfi olmayan örnekler aşağıdaki nedenlerden kaynaklanabilir¹²⁸:

- 1) Duruma dayalı örnekleme kullanılarak başarısız işletmelerin aşırı örneklenmesi,
- 2) Tam veri örnek seçim kriterinin uygulanması,
- 3) Başarısız ve başarılı işletmelerin eşleştirilmiş örneklerinin kullanılması.

Başarısız işletmelerin toplam popülasyon içerisindeki payının düşük olmasından dolayı, çoğu araştırmacılar duruma dayalı bir örnek tercih etmektedirler. Yani, örnekteki

¹²⁶ Balcaen; Ooghe; a.g.e, p.22.

¹²⁷ Zmijewski; a.g.e., pp.79-80.

¹²⁸ Balcaen; Ooghe; a.g.e., p.23.

işletmelerin seçimi, işletmelerin önceden bilinen başarısız ya da başarılı olma durumlarına dayanmaktadır. Bu da başarısız işletmelerin aşırı örneklenmesiyle sonuçlanmaktadır. Bununla birlikte, başarısızlık tahmin modellerinin geliştirilmesinde kullanılan tekniklerin çoğu tesadüfi örnekleme varsayımına dayandığından, başarısız işletmelerin aşırı örneklenmesi, tercihe dayalı bir örnek yanlılığıyla sonuçlanabilmektedir¹²⁹. Öyle ki, bu tür örnekler üzerinde oluşturulan modeller, başarılı işletmeleri daha yüksek bir olasılıkla yanlış sınıflandırmak pahasına, başarısız işletmelerin yanlış sınıflandırılmasıyla ilgili daha düşük hata oranları göstereceklerdir. Aslında, 1. tip hata (başarısız işletmelerin yanlış sınıflandırılması) maliyetleri genellikle 2. tip hata (başarılı işletmelerin yanlış sınıflandırılması) maliyetlerinden daha yüksek olduğu için, bu durum yararlı olarak düşünülebilir. Buna rağmen, model tahmin için kullanıldığında bazı başarılı işletmeler için başarısızlık sinyalleri elde edilecektir.

Platt ve Platt (2002), çalışmalarında tercihe dayalı örnek yanlılığı ile ilgili ampirik kanıtlar bulmuşlar ve bazı çalışmalarda raporlanan sınıflandırma doğruluklarının yanıltıcı olduğunu ileri sürmüşlerdir¹³⁰.

Tesadüfi olmayan örneklemenin ikinci nedeni, tam veri örnek seçim kriteridir. Finansal başarısızlık tahmini alanında çalışma yapılırken sık sık eksik verilerle karşılaşıldığı için, bazı araştırmacılar söz konusu kriteri kullanmaktadırlar. Yani, eksik verileri olan işletmeleri örneğe dahil etmeyerek sadece verileri tam olan işletmeler üzerinde çalışmaktadırlar. Bu durum, örnek seçim yanlılığına neden olabilir¹³¹. Uygulamada, başarısız işletmelerin eksik verilere sahip olması daha olasıdır. Çünkü, başarısız işletmeler genellikle daha yeni ve daha küçük işletmelerdir. Bu nedenle, tam veri örnek seçim kriterine dayalı olarak tahmin modeli oluşturmak, başarısız işletmelerin daha çok yanlış sınıflandırılmasıyla sonuçlanacaktır.

Finansal başarısızlığın tahmini alanında yapılan çalışmaların büyük bir kısmında, başarısız ve başarılı işletmelerin eşleştirilmiş örneği kullanılmıştır. Yani, her bir

¹²⁹ Zmijewski; a.g.e., p.65.

¹³⁰ Harlan D. Platt and Marjorie B. Platt; "Predicting Corporate Financial Distress: Reflections on Choice-Based Sample Bias", *Journals of Economics and Finance*, Vol. 26, No. 2, 2002, pp.184-199.

¹³¹ Zmijewski; a.g.e., p.74.

başarısız işletme için bazı kriterler dikkate alınarak eşleştirilmiş başarılı bir işletme seçilmektedir. Bu durumda, modelin oluşturulmasında kullanılan örneğin yarısı başarısız işletmelerin verilerini, yarısı da başarılı işletmelerin verilerini kapsamaktadır. Eşleştirme, genellikle büyüklük, sektör ve yaş kriterleri dikkate alınarak yapılmaktadır. Eşleştirmenin sağladığı en önemli yararlarından biri, tahmin gücü olduğuna inanılan fakat tahminci değişkenler içerisinde yer almayan bazı değişkenlerin, araştırmacılar tarafından kontrol edilmesine olanak tanınmasıdır. Eşleştirmenin en önemli nedeni; başarısız işletmelerin genellikle daha küçük olması ve belirli başarısız sektörlerde yoğunlaşmasıdır. Bu nedenle, tesadüfi örnekleme kullanıldığında, başarısız ve başarılı işletme grupları arasında büyüklük ve sektör açısından muhtemelen büyük farklılıklar bulunacaktır. Bunun sonucu olarak da, başarısız ve başarılı işletmeler arasında ayırım yapmak amacıyla oluşturulan model, gerçekte büyük ve küçük işletmeler arasında veya farklı sektörler arasında ayırım yapan bir model olarak ortaya çıkabilecektir¹³².

Eşleştirilmiş örneklerin kullanılması, yukarıda anlatılan bazı yararları sağlamakla birlikte birtakım ciddi dezavantajlara da sahiptir. Söz konusu örnekleme yönteminde, başarılı işletmelerin örneği başarısız işletmelerin özelliklerine göre oluşturulduğu için, bu örnek büyük bir ihtimalle başarısız işletmelerin toplam popülasyonunu temsil edici nitelikte olmayacaktır. Bazı özelliklerin az temsil edilmesinden dolayı, çalışmanın örneğe özgü bir başarısızlık tahmin modeliyle sonuçlanması olasıdır. Zmijewski, toplam popülasyondan önemli derecede farklılık gösteren eşleştirilmiş örnekler kullanmanın, belirli koşullar altında logit modellerinde taraflı katsayılara neden olduğunu göstermiştir¹³³.

Eşleştirilmiş örneklerle ilgili diğer bir problem, eşleştirme kriterinin seçimiyle ilgilidir. Söz konusu kriter genellikle gelişigüzel olarak seçilmektedir. Eğer seçilen kriter başarısızlık olasılığıyla bağlantılıysa, bu durum seçim yanlılığına neden olabilir. Örneğin, eşleştirme kriteri olarak büyüklüğün seçilmesi, bazı problemler ortaya çıkarabilir. Çünkü, küçük işletmeler genellikle başarısızlığa büyük işletmelerden daha

¹³² Hannah Bishop; Cecilio Mar Molinero; Michael Turner; "Multidimensional Scaling Analysis as a Tool to Explain Company Distress: The Case of Marks&Spencer PLC", 27 Congreso Nacional de Estadística e Investigación Operativa, Lleida, 8-11 de abril de 2003, p.4.

¹³³ Zmijewski; a.g.e., p.65.

eğilimli oldukları için, büyüklük değişkeni tek başına önemli bir ayırıcı değişken olabilir. Eşleştirme kriteri olarak seçilen değişkenin tahmin gücü elendiğinden, genel bir tahmin modeli yerine sınırlı bir başarısızlık tahmin modeli ortaya çıkacaktır. Eşleştirilmiş örneklemin son bir dezavantajı ise uygulamada çeşitli kriterlere dayanan çok değişkenli bir eşleştirme yapmanın zorluğudur¹³⁴.

Mevcut çalışmalarda kullanılan başarısız işletmelerin toplam örnek içerisindeki oranı, gerçek popülasyon oranından büyük ölçüde daha yüksektir. Dun&Bradstreet, Amerika'daki işletme başarısızlıklarının frekans oranının, 1934 yılından bu yana asla % 0,75'i geçmediğini raporlamaktadır. Buna karşılık, bugüne kadar yapılan çalışmalar arasında başarısız işletmelerin toplam örnek içerisindeki payının % 2'den daha düşük olduğu bir çalışmaya rastlanamamıştır¹³⁵. Hatta, pek çok çalışmada eşleştirilmiş örnekleme kullanıldığından söz konusu oran % 50'dir. Bunun en önemli nedenlerinden biri, örneğin gerçek dünyadaki ağırlığına göre tesadüfi olarak seçilmesi durumunda, model sadece başarılı işletmeleri doğru tahmin etmeye başlayacaktır. Başarılı işletmelerin oranı fazla olduğundan, toplam sınıflandırma doğruluğu yüksek görülecektir. Halbuki, başarısız işletmeleri doğru tahmin edebilmek daha önemlidir. Bu nedenle, başarısız işletmelerin popülasyondaki ağırlığından daha fazla bir ağırlıkla örneğe dahil edilmesi, 1. tip hata oranını azaltacağından faydalı olarak görülmektedir.

Örnekle ilgili bir diğer sorun ise örneğin büyüklüğüdür. Özellikle lojistik regresyon analizi ve yapay sinir ağları, iyi bir tahmin modeli kurabilmek için diskriminant analizine kıyasla daha çok sayıda işletmeden oluşan örneğe ihtiyaç duymaktadırlar.

2.2.2. İkili Bağımlı Değişken Varsayımıyla İlgili Problemler

Daha önce bahsedildiği gibi, geleneksel istatistiki yöntemlerden en yaygın olarak kullanılanları çok değişkenli diskriminant analizi ve lojistik regresyon analizidir. Her iki yöntem de bağımlı değişkenin ikili olduğu varsayımına dayanmaktadır. Dolayısıyla, söz konusu yöntemler finansal başarısızlık tahmini alanına uygulandığında, başarısız ve

¹³⁴ Balcaen; Ooghe; a.g.e., p.24.

¹³⁵ Lawrence A. Weiss; "The Impact of Incorporating the Cost of Errors into Bankruptcy Prediction Models", 19th Annual Congress of the European Accounting Association, Bergen, Norway, 1996, p.3.

başarılı işletme popülasyonlarının açık şekilde birbirlerinden farklı olduğu varsayılmaktadır. Bununla birlikte, gerçekte başarısız ve başarılı işletmeler arasında açık bir ayırım yapmak çok da kolay değildir.

Araştırmacılar, geleneksel istatistiki yöntemlerle tahmin modelleri oluştururken, işletmeleri başarısız ve başarılı popülasyonlara keyfi bir şekilde ayırmaktadırlar. İlk keyfi faktör, başarısızlığın tanımıyla, diğer keyfi faktör ise işletmeleri başarısız ve başarılı popülasyonlara ayırmada kullanılan yöntemle ilgilidir. Bu keyfi faktörlerin bir sonucu olarak, bağımlı değişkenin ikili olduğu temel varsayımı ihlal edilmektedir ve modelleme yöntemleri uygun olmayan bir tarzda kullanılmaktadır. Bu konuyla ilgili problemler aşağıda ayrıntılı olarak anlatılmaktadır.

Finansal başarısızlık tahmin çalışmalarında, başarısız ve başarılı işletme popülasyonları, tümüyle araştırmacının başarısızlık tanımına bağlıdır. Bu tür çalışmalarda genellikle iflas, başarısızlık, acizlik, tasfiye ve borçları ödemede temerrüde düşme gibi terimler kullanılmaktadır ve kimi zaman bu terimler aynı başarısızlık kavramını göstermektedir.

Pek çok çalışmada başarısızlığın yasal tanımı olan iflas kullanılmaktadır. Başarısızlığın yasal tanımı geniş ölçüde kabul görmüş olmakla birlikte, bazı problemlere neden olabilmektedir. Bu problemlerden ilki, yasal başarısızlık zamanının çoğu zaman gerçek başarısızlık zamanını yansıtmamasıdır. Başarısızlığın gerçek zamanı ile yasal durumdaki değişim zamanı (iflasın mahkeme tarafından ilan edilmesi) arasında büyük bir fark bulunması muhtemeldir. Diğer bir problem ise başarısız işletmelerden bazılarının yasal durumlarında bir değişiklik olmaması olasılığıdır. Diğer bir ifadeyle, başarısız işletme özelliklerinden bazılarını sahip bir işletme iflas etmeyebilir. Ayrıca, böyle bir işletme bazen yasal durumda değişiklik (iflas gibi) göstermek yerine başka bir işletmeyle birleşebilir ya da yeniden organize edilebilir¹³⁶. Başarısızlığın yasal tanımının kullanılmasıyla ilgili problemlerden dolayı, bazı araştırmacılar yasal tanımın çok dar olduğunu ve daha geniş bir kavram olan finansal başarısızlık üzerinde çalışmanın uygun olacağını ileri sürmektedirler.

¹³⁶ Balcaen; Ooghe; a.g.e., p.19.

Bununla birlikte, bu tür çalışmalarda finansal başarısızlık kavramını kullanmanın da önemli bir kusuru bulunmaktadır. Çünkü, finansal başarısızlığın istikrarlı bir tanımı yoktur ve finansal başarısızlık kriteri araştırmacı tarafından keyfi olarak tercih edilmektedir. Yapılan çalışmalarda kullanılan bazı finansal başarısızlık kriterleri şunlardır:

- Varlıkların belirli oranda azalması,
- Sermayenin belirli oranda azalması,
- İşletmenin çeşitli yıllarda üst üste zarar etmesi,
- Borçların ödenememesi,
- İflas vb.

Finansal başarısızlık tahmini alanında yapılan çalışmalarda, başarısız işletmeleri tanımlamak için çoğunlukla birden fazla finansal sıkıntı kriteri bir arada kullanılmaktadır. Ancak, finansal başarısızlığın tanımındaki istikrarsızlık ve keyfilik nedeniyle bazı araştırmacılar, farklı finansal sıkıntı türleri için farklı modeller geliştirmenin daha uygun olacağını ileri sürmektedirler¹³⁷.

Başarısız ve başarılı örnekleri oluşturmadaki diğer bir keyfi faktör de seçilmiş başarısızlık tanımı uygulanırken izlenen yolla ilgilidir. Başarısızlık kriteri, gelişigüzel seçilmiş bir zaman dönemine uygulandığında, işletmelerin başarısız ve başarılı gruplara ayrımı suni nitelikte olmaktadır. Öyle ki, iki popülasyon sadece seçilmiş zaman döneminde birbirini dışlamaktadır. Bu nedenle, başarısızlık kriterinin keyfi olarak seçilmiş zaman dönemine uygulanması, bir seçim yanlılığını içerir ve uygun olmayan örneklerle sonuçlanabilir. Örneğin, seçilmiş zaman diliminden bir yıl sonra başarısızlık kriterine sahip olan bir işletme, söz konusu dönemde başarısız grubun bazı özelliklerini göstermesine rağmen başarılı işletmeler grubuna dahil edilecektir. Seçim taraflılığı problemi, daha geniş bir zaman dilimi kullanılarak çözümlenebilir. Mesela, başarılı işletme grubuna sadece belirlenen zaman döneminin beş yıl sonrasına kadar başarısızlık kriterini taşımayan işletmeler dahil edilebilir. Ooghe ve diğerleri (1993), yanlılık

¹³⁷ Keasey; Watson; "Financial Distress Prediction Models: A Review of Their Usefulness", p.92.

problemini dikkate almada bu tekniği kullanmışlardır. Aksine, Back ve diğerleri (1997) ise seçim taraflılığı problemini kabul etmekle birlikte bazı başarısızlık özelliklerine sahip işletmelerin de başarılı olarak örneğe dahil edilmesinin daha iyi olduğunu ileri sürmektedirler¹³⁸.

Son bir husus, çoğu finansal başarısızlık tahmin modelinin açık bir şekilde ikiye ayrılmış popülasyonlar (başarısız işletmelerin yer aldığı riskli grup ve başarılı işletmelerin yer aldığı riskli olmayan grup) üzerinde geliştirilmesiyle ilgilidir. Halbuki, gerçek hayatta işletmeler tam başarısız ve tam başarılı olarak düşünülen iki uç arasında pek çok durumda bulunabilirler. Bu soruna çözüm olarak, literatürde ikiden fazla başarı durumunu dikkate alarak yapılan çalışmalar bulunmaktadır.

2.2.3. Bağımsız Değişkenlerin Seçimiyle İlgili Problemler

Finansal başarısızlık tahmin çalışmalarının büyük çoğunluğunda model oluşturmaya, literatürdeki popülariteleri ve daha önceki çalışmalardaki tahmin başarıları esas alınarak gelişigüzel olarak seçilmiş geniş bir değişkenler setiyle başlanır. Bunun nedeni, değişkenlerin seçimi için teorik bir temel bulunmayışıdır. Ancak, popülaritelerine dayanarak değişkenleri seçmenin bazı problemlere neden olabileceği unutulmamalıdır.

Değişkenlerin başlangıç setini belirlemede, bazı araştırmacılar istatistiksel yöntemler de kullanmışlardır. Araştırmacılar değişkenleri; hesaplanan parametrelerin istatistiksel önemi, değişkenlerin her birinin tek başına ayırma yeteneği (tek değişkenli analizde), değişkenlerin katsayılarının işareti, temel bileşenler analizi, faktör analizi, finansal oranların farklı kombinasyonlarının sınıflandırma sonuçları veya aşamalı (stepwise) metodlar (ileri doğru seçim ya da geriye doğru eleme metodları gibi) esasında seçmektedirler. İstatistiksel yöntemler kullanılırken genellikle değişkenlerin başarısızlıkla ilgisi ihmal edilirken, istatistiksel özellikleri vurgulanmaktadır. Değişkenlerin istatistiki hususlara dayalı olarak seçiminin bazı olumsuz sonuçlara sahip olduğu ve bu nedenle de bazı eleştirilere maruz kaldığı bilinmektedir.

¹³⁸ Balcaen; Ooghe; a.g.e., pp.20-21.

Değişkenlerin ampirik olarak seçilmesinin ilk olumsuz sonucu, başarısız ve başarılı işletmeler arasında hangi değişkenlerin en iyi ayrımı yaptığı konusunda bir fikir birliği bulunmamasıdır. Literatürde yer alan ampirik çalışmalarda, en iyi tahminci değişkenler konusunda birliktelik yoktur. İyi sınıflandırma sonuçlarına sahip, her biri farklı sayıda ve farklı değişkenlerden oluşan çok sayıda başarısızlık tahmin modeli vardır.

İkinci olumsuz sonuç, değişkenler ampirik olarak seçildiğinde, modeldeki değişkenler genellikle kullanılan örneğe bağlı olmaktadır. Bu nedenle de ampirik bulgular kimi zaman genelleme yapmak için uygun olmayabilir.

Değişkenlerin ampirik olarak seçilmesinin bir diğer olumsuz sonucu da, başarısızlık tahmin modelinin bazı katsayılar için sezgilerin karşıtı işaretler gösterebilmesidir. Bu modeller, kestirim örneklerindeki işletmeleri en iyi şekilde sınıflandıran bir değişkenler kombinasyonu kullanmaktadırlar. Söz konusu modeller, değişkenlerin finansal durumla ilgili önemini ihmal etmektedirler. Bazen finansal oranlar arasındaki yüksek korelasyon, bazı değişkenlerin katsayılarına beklenmedik işaretler atanmasına neden olabilmektedir. Bu durum, iyi bir tahmin modelinin dikkatli bir şekilde seçilmiş bazı değişkenleri kapsamı gerektiği ve bu değişkenlerin sezgisel olarak doğru olan yönde kullanılması gerektiği genel görüşüyle çelişmektedir¹³⁹.

Ampirik olarak değişkenlerin seçimine başvurmayan, belirli bir teoriden yararlanan araştırmacılar da bulunmaktadır. Değişkenlerin teorik olarak seçildiği çalışmaların çoğu, belirli bir nakit akım teorisine dayanmaktadır. Beaver'in 1967'de yapmış olduğu çalışma, nakit akım teorisini kullanan ilk çalışmadır. Bu çalışmada işletme, nakit girişleri tarafından doldurulan ve nakit çıkışları tarafından boşaltılan bir havuz olarak görülmektedir. Benzer şekilde bir nakit akım teorisi, Blum'un 1974'te oluşturduğu modelin esasını teşkil etmektedir. Bu konuda yapılmış pek çok çalışma bulunmaktadır. Gentry, Newbold ve Whitford (1985)¹⁴⁰; Gentry, Newbold ve Whitford (1987)¹⁴¹; Aziz,

¹³⁹ A.g.e., p.38.

¹⁴⁰ James A. Gentry; Paul Newbold and David T. Whitford; "Classifying Bankrupt Firms with Funds Flow Components", Journal of Accounting Research, Vol. 23, No.1, 1985, pp.146-160.

¹⁴¹ James A. Gentry; Paul Newbold and David T. Whitford; "Funds Flow Components, Financial Ratios and Bankruptcy", Journal of Business Finance & Accounting, Vol. 14, No. 4, 1987, pp.595-606.

Emanuel ve Lawson (1988)¹⁴² bunlardan bazılarıdır. Sharma (2001)¹⁴³ yaptığı çalışmada, işletme başarısızlığı alanında nakit akımının kullanımıyla ilgili çalışmaları ayrıntılı bir şekilde incelemiştir. Literatürde, nakit akım bilgisinin başarısızlık tahmin modellerine ilave bir değer katmadığı yönünde bir görüş hakimdir. Sharma tarafından yapılan çalışmanın sonuçları da bu görüşü güçlendirmektedir.

Nakit akım teorilerinin dışında teorik modeller de kullanılmıştır. Wilcox (1971) değişken seçimini “kumarbazın iflası modeli” ne dayandırmıştır. Söz konusu modelde, işletme başlangıçta belirli bir para miktarına sahip bir kumarbaz olarak görülmektedir. Charitou ve Trigeorgis (2000)¹⁴⁴ ise değişkenleri seçmede opsiyon fiyatlama teorisini kullanmıştır. Keasey ve Watson (1987) ise Argenti'nin hipotezlerine dayalı olarak değişkenleri belirlemişlerdir¹⁴⁵. Literatürde, değişkenlerin seçimini teorik esaslara dayandırmada bunlar ve bunlara benzer çalışmalar bulunmasına karşın, işletme başarısızlığı için eşsiz bir teori henüz geliştirilememiştir. Geliştirilen teorik zeminler de çok basitleştirilmiş veya çok belirsizdirler.

Bazı finansal başarısızlık tahmin çalışmaları ise tahminci değişkenleri herhangi bir teorik ya da ampirik hususu dikkate almaksızın seçmiştir.

Bağımsız değişkenlerin seçimiyle ilgili diğer bir problem, çalışmalarda kapsanan bazı oranların birbiriyle örtüşmesi ya da yüksek derecede ilişkili olmasıdır¹⁴⁶. Örneğin; aşağıda yer alan oranların hepsi de “Toplam Varlıklar = Yabancı Kaynaklar + Öz Kaynaklar” bilanço denkliğinin birer varyantıdır.

¹⁴² Abdul Aziz; David C. Emanuel and Gerald H. Lawson; “Bankruptcy Prediction – An Investigation of Cash Flow Based Models”, Journal of Management Studies, Vol. 25, No. 5, 1988, pp.419-437

¹⁴³ Divesh S. Sharma; “The Role of Cash Flow Information in Predicting Corporate Failure: The State of the Literature”, Managerial Finance, Vol. 27, No. 4, 2001, pp. 3-28.

¹⁴⁴ Andreas Charitou; Lenos Trigeorgis; “Option-Based Bankruptcy Prediction”, EFMA (European Financial Management Journal) 2000 Athens, 2000, 27p.

¹⁴⁵ Keasey; Watson; “Non-Financial Symptoms an the Prediction of Small Company Failure: A Test of Argenti's Hypotheses”, pp.335-354.

¹⁴⁶ Kung H. Chen and Thomas A. Shimerda; “An Empirical Analysis of Useful Financial Ratios”, Financial Management, Spring 1981, p.53.

- Toplam Yabancı Kaynaklar / Toplam Varlıklar

- Öz Kaynaklar / Toplam Varlıklar

- Toplam Yabancı Kaynaklar / Öz Kaynaklar

Chen ve Shimerda, 1981 yılındaki çalışmalarında böyle örtüşmelerin ortadan kaldırılmasının faydalı finansal oranlar seti geliştirmede yardımcı olacağını ileri sürmektedirler.

2.2.4. Finansal Oranların Kullanımıyla İlgili Problemler

Çeşitli yöntemler kullanılarak geliştirilen modellerin çoğu, başarısızlığı tahmin etmede sadece finansal oran biçimindeki yıllık mali tablo verilerini kullanmaktadırlar. Bunun en önemli nedenleri, finansal oranların objektif ölçüler olması ve halka açık bilgilere dayanmasıdır. Buna karşılık, finansal oranların kullanımıyla ve yıllık mali tablo verileriyle sınırlanmış başarısızlık tahmin modelleri için ciddi eleştiriler de bulunmaktadır. Finansal oranların kullanımıyla ilgili eleştiriler, aşağıda ayrıntılı olarak anlatılmaktadır. Tüm bu eleştirilere rağmen, başarısızlık tahmininde finansal oranların son derece önemli olduğu unutulmamalıdır.

Finansal oranların kullanımıyla ilgili ilk eleştiri şudur: Yıllık mali tabloların düzenlenmesi ve yayınlanması zorunluluğu, genellikle işletme türü ya da büyüklüğü gibi belirli bir kriterle bağlıdır. Bundan dolayı, finansal oranlar kullanılarak oluşturulan modeller sadece bu kriteri karşılayan işletmelerin verileriyle sınırlanmaktadır. Örneğin, Türkiye’de sadece halka açık şirketler mali tablolarını yayınlamak zorunda olduğundan, genellikle çalışmalar bu işletmeler üzerinde yapılmaktadır. Bu yüzden pek çok çalışma varlık büyüklüğü, satış seviyesi ve çalışan sayısı gibi belirlenen kriterleri karşılayan büyük işletmelerle sınırlıdır.

Finansal oranlara dayalı olarak başarısızlık tahmin modeli oluşturulduğunda, araştırmacılar dolaylı olarak, mali tabloların işletmelerin finansal durumunu doğru bir şekilde yansıttığını varsaymaktadırlar. Buna karşılık, bazen mali tabloların doğru ve güvenilir olmadığı bilinmektedir. İşletmelerin karlarındaki azalmayı ya da zararlarını

gizlemeye ve finansal durumu daha olumlu bir şekilde göstermeye eğilimli olduklarını iddia eden çeşitli akademik çalışmalar vardır¹⁴⁷. Özellikle başarısız işletmelerde, bir savunma mekanizması olarak bu eğilimin daha güçlü olduğu düşünülebilir. Dolayısıyla, manipüle edilmiş mali tablolardan elde edilen finansal oranların kullanılması, başarısızlık tahmin modellerinin güvenilirliğini tartışmalı kılmaktadır.

Finansal oranların kullanımıyla ilgili bir diğer problem ise oranların hesaplanmasında kullanılan yıllık mali tablolardaki bazı kalemlere ilişkin değerlerin eksik olmasıdır. Eksik değerlerin üstesinden gelmek için, eksik değere sahip işletmeler örnekten çıkarılabilir ya da eksik değerler ortalama veya rasgele değerlerle tamamlanabilir. Kimi zaman mali tablolardan hesaplanan bazı finansal oranlar uç değerlere sahip olabilmektedir. Modelde yer alan bazı oranlar için uç değerlerin (ortalamadan oldukça farklı çok yüksek ya da çok düşük değerler) varlığı, modeldeki bu orana ilişkin katsayıyı etkileyebilir. Bu problem, uç değerler yerine o oranın örnekteki ortalama değerini koyarak çözülebilmektedir. Özellikle lojistik regresyon analizinin, uç değerlere karşı duyarlı olduğu bilinmektedir.

Finansal başarısızlık tahmini alanında yapılan çalışmalarda genellikle sadece halka açık bilgiler kullanılabilir. Finansal oranlar da halka açık bu bilgilerden hesaplanmaktadır. Bu tür modeller, işletmelere ilişkin özel verileri içeren modeller kadar duyarlı olmayabilir. Bu tür özel verilere ulaşabilecek gruplar ise sadece yönetim ve işletmenin denetçileridir.

Araştırmacılar, başarısızlık tahmin modellerine sadece finansal oranları dahil ettiklerinde, dolaylı olarak tüm başarı ya da başarısızlık göstergelerinin (işletme içi ve işletme dışı) mali tablolara yansıdığını varsaymaktadırlar. Bununla birlikte, başarı ya da başarısızlıkla ilgili tüm bilgilerin bilanço ve gelir tablosunda yer almadığı açıktır. Bu bağlamda, Argenti (1976) finansal oranların yanlış giden bazı şeyleri gösterebileceğini fakat tek başlarına başarısızlığı tahmin edemeyeceklerini ileri sürmektedir¹⁴⁸.

¹⁴⁷ Bishop; Mar Molinero; Turner; a.g.e., p.2.

¹⁴⁸ Balcaen ve Ooghe, A.g.e., p.30.

Bu nedenle, bazı akademisyenler nitel ya da muhasebe dışı göstergelerin de başarısızlık tahmin modellerine dahil edilmesini tavsiye etmektedirler. Bu tür göstergelerin sayısı oldukça fazladır. Personel politikası, yönetim tecrübesi, ortakların sayısı, işletme için uzun vadeli makul bir işletme stratejisinin varlığı, üretim verimliliği, müşteri yoğunluğu, az sayıda tedarikçiye bağımlı olunması, ihracat durumu, aynı bölgede büyük rakiplerin varlığı, bankalarla ilişkiler ve çeşitlendirme seviyesi, sektörün kârlılığı, sektör büyüme oranı, pazar payı gibi stratejik değişkenler bunlardan bazılarıdır. Bu listeyi uzatmak mümkündür.

Ayrıca, bir işletme tek başına faaliyet göstermemektedir, çevresiyle sürekli olarak etkileşim içindedir. Bu nedenle, başarısızlık tahmin modellerinde dış çevre hakkındaki bilgiler de dikkate alınmalıdır. Dikkate alınması gereken en temel unsur, makroekonomik durumdur. Makroekonomik değişkenlerin finansal başarısızlık tahminindeki önemi konusunda pek çok çalışma bulunmaktadır. Bu çalışmaların bazılarında, makroekonomik değişkenleri ilave etmenin finansal başarısızlık tahminine olumlu katkıda bulunduğu sonucuna ulaşılrken, bazılarında makroekonomik değişkenleri eklemenin ilave yarar sağlamayacağı görülmüştür. Finansal başarısızlık tahmin çalışmalarının önemli bir kısmında kullanılan yaklaşım, makroekonomik faktörlerin etkisinin işletmenin finansal oranlarına yansıdığını varsayarak, söz konusu değişkenleri ayrıca kullanmamak yönündedir.

Finansal oranların kullanımıyla ilgili bir diğer problem, finansal oranların farklı bileşenlerden oluştuğu gerçeğiyle ilgilidir. Bu bileşenlerden her biri, işletmenin finansal durumu hakkında farklı bir bilgi yansıtmaktadır. Başarısız ve başarılı işletmelerde belirli oranların bileşenleri açık şekilde birbirinden farklı olmasına karşın, oran değerleri arasında önemli bir farklılık olmayabilir. Bu nedenle, bazı durumlarda finansal oranlar yerine, söz konusu oranların bileşenlerini kullanmak daha anlamlı olabilmektedir. Örneğin, bir işletmedeki aşırı derecede düşük “net kâr marjı”, çok yüksek bir “toplam varlık devir hızı” tarafından telafi edilmiş olabilir ve normal seviyede bir “toplam varlıkların kârlılığı” oranı ortaya çıkabilir. Başka bir işletmede ise yüksek “net kâr marjı” ve düşük “toplam varlık devir hızı” bulunmasına karşın, benzer bir “toplam varlıkların kârlılığı” oranı görülebilir. Bundan dolayı, finansal oran bileşenlerini ayrı ayrı incelemek yararlı olabilmektedir.

Bağımsız değişkenlerin seçimi meselesinde de belirtildiği gibi, literatürde hangi tür finansal oranların en iyi başarısızlık göstergeleri olduğu konusunda fikir birliği yoktur.

Ancak, tüm bu eleştirilere ve sınırlamalara karşın, başarısızlıktan önceki yıllarda başarısız ve başarılı işletmelerin birtakım oranlarının birbirinden farklı olduğu öne sürülmektedir¹⁴⁹. Bu nedenle pek çok çalışmada olduğu gibi bu çalışmada da finansal oranlar kullanılmıştır.

Finansal oranlarla ilgili yukarıda bahsedilen problemlere ilaveten, başarısızlık tahmin modelleri kurulurken genellikle her bir işletme için sadece bir yıla ilişkin mali tabloların kullanılması da bazı sorunlara neden olmaktadır. Bilindiği gibi bilançolar, işletmenin finansal durumunun sadece o andaki fotoğrafını vermektedir. Bu nedenle de tek yıla ait bilançodan elde edilen verilere dayalı başarısızlık tahmin modelleri yanıltıcı olabilir. Örneğin, bilanço tarihinde belirli bir göstergeye göre geçici sıkıntı içinde olan bir işletme, aslında başarılı olmasına rağmen başarısız işletmeler örneği arasında yer alabilir.

Sadece bir yıla ilişkin mali tablolardan elde edilen finansal oranlar üzerinde kurulan başarısızlık tahmin modelleri, değişkenlerin zaman serisi davranışlarını hesaba katmamaktadır. Dolayısıyla, işletme performansıyla ilgili önemli geçmiş veriler yok sayılmaktadır. Bazı araştırmacılar, işletme başarısızlık tahmininin sadece bir yıllık mali tablolara dayalı olarak yapılmaması gerektiğini, daha fazla yıla ait verilerin ve finansal durumdaki değişimin dikkate alınması gerektiğini ileri sürmektedirler. Bu kapsamda finansal başarısızlığın tahmin edilmesinde finansal oranların trendini de hesaba katmak uygun olabilecektir.

Tek bir yıla ait mali tablolara dayalı olarak başarısızlık tahmin modeli oluşturulurken, her bir işletmenin hangi yıla ait mali tablolarının kullanılacağına genellikle gelişigüzel olarak karar verilmektedir. Bundan kaynaklanan bazı problemler bulunmaktadır. Birincisi, işletme verilerinin ait olacağı yılın tercihi, nihai modelde bir seçim yanlılığı ortaya çıkarmaktadır. İkincisi, bir modelin uygulanabilirliği, model oluşturulurken kullanılan mali tablolar (başarısızlık olayından bir, iki veya üç yıl önceki tablolar)

¹⁴⁹ Bishop; Mar Molinero; Turner; a.g.e., p.2.

tarafından saptanmaktadır. Diğer bir ifadeyle, olaya tahmin bağlamında bakıldığında hangi yıla ait mali tabloların kullanıldığına bağlı olarak, model t-1, t-2 veya t-3 yılındaki başarı/başarısızlık durumlarıyla ilgili bir sınıflandırma tablosu sağlamaktadır. Örneğin, başarısızlık tahmin modeli başarısızlıktan üç yıl önceki veriler üzerinde oluşturulmuşsa, model daha kısa bir dönemde başarısızlığı tahmin etmek için kullanıldığında zayıf tahmin sonuçlarına sahip olabilir ya da bir bütün olarak güvenilmez olabilir. Çünkü model, t-3 yılındaki başarısızlık olasılığının belirtisini sunmaktadır. Ayrıca, tahmin modeli başarısızlıktan önceki farklı yıllara ait veriler üzerinde oluşturulduğu zaman, büyük olasılıkla değişkenler ve katsayılar birbirlerinden farklı olmaktadır.

Finansal başarısızlık tahmininde kullanılan yöntemlerden sadece diskriminant analizine özgü olan bir problem de verilerin normal dağılımı sorunudur. Diskriminant analizi, verilerin normal dağıldığını varsaymaktadır. Uygulamada, sıklıkla değişkenlerin çoklu normal dağılıma sahip olmadığı görülmektedir. Bu durum, anlamlılık testlerinde ve hesaplanan hata oranlarında yanlılığa neden olabilmektedir. Çok değişkenli normal dağılım, önsel olarak tek değişkenli normal dağılımı gerektirmektedir. Bu yüzden, bazı araştırmacılar tek değişkenli normallığı test ederek çok değişkenli normallığı test etmeyi ihmal etmektedirler. Finansal başarısızlık tahmin modellerinde çoğunlukla değişken olarak kullanılan finansal oranlar, genellikle normal olmayan bir dağılım göstermektedir. Bazı çalışmalarda, model oluşturulmadan önce çeşitli dönüşümler yardımıyla tek değişkenli normal olmayan dağılım düzeltilir ya da oranlar tek değişkenli normal dağılıma yaklaştırılır. Literatürde, değişkenleri normal dağılıma yaklaştırmak için kullanılacak uygun dönüşümle ilgili genel kabul görmüş ilkeler bulunmamaktadır. Değişkenlerin dönüştürülmesi, normal dağılımla sonuçlanabilmesine karşın, çok değişkenli normallik varsayımı halen sağlanamayabilir ve dönüşüm değişkenler arası karşılıklı ilişkileri değiştirerek çok değişkenli diskriminant modelini bozabilir¹⁵⁰. Netice olarak, bu meselenin dikkatli bir şekilde ele alınması gerektiği açıktır. Uygulamada çoğunlukla diskriminant modelinin performansı yüksek çıktığı zaman verilerin normal dağılıp dağılmadığına bakılmamakta, sınıflandırma doğruluğu düşük olduğunda bu sorun incelenmektedir. Ayrıca, normal dağılım varsayımı gerektirmeyen lojistik

¹⁵⁰ Balcaen; Ooghe; a.g.e., p.11.

regresyon analizi ve yapay sinir ağıları gibi yöntemlerin kullanılması da soruna çözüm olarak düşünülebilir.

Çoklu bağıntı meselesi de finansal oranların kullanımıyla ilgili önemli bir konudur. Çoklu bağıntı, bağımsız değişkenler olarak kullanılan finansal oranların kendi aralarında yüksek korelasyon göstermesidir. Bu durum, bazı istatistiki yöntemlerde katsayıların standart hatasını etkileyerek anlamlılık testlerinin yanlı çıkmasına neden olmaktadır. Bunun için çoklu bağıntı, finansal oranlardan hangilerinin önemli olduğu konusunda araştırmacıları yanıltabilmektedir. Literatürde bu konuyla ilgili yaygın görüş, istatistiki yöntemlerin bu sorundan fazla etkilenmediği yönündedir. Modelin tahmin doğruluğuna katkıda bulunduğu müddetçe, birbiriyle yüksek derecede ilişkili değişkenleri kapsamada fayda görülmektedir¹⁵¹.

2.2.5. Durağan Olmama ve Veri İstikrarsızlığıyla İlgili Problemler

Kurulan modelin tahmin bağlamında kullanılması, değişkenler arası ilişkilerin zaman içerisinde kararlı olmasını ve gelecekte model tarafından sınıflandırılacak olan işletmelerdeki ilişkilerin, örnekteki işletmelerinkiyle aynı olmasını gerektirir. Bunlardan birincisi, bağımsız değişkenler ve bağımlı değişken arasındaki ilişkinin zaman içerisinde kararlı olması gerektiği anlamına gelir. Buna durağanlık varsayımı denir. İkinci olarak, eğer modeldeki bağımsız değişkenler arasında ilişkiler varsa, bu ilişkiler durağan olmalıdır ve diğer örneklerde de tekrarlanmalıdır. Durağan olmama probleminin, bağımsız değişken değerlerinin ortalama yapısının, modeli oluşturma dönemi ve tahmin dönemi arasında önemli derecede farklı olduğu anlamına gelen veri istikrarsızlığıyla yakından ilgili olduğu açıktır¹⁵².

Literatürde, veri istikrarsızlığı ve durağan olmama problemleriyle ilgili pek çok kanıt bulunmaktadır. Barnes (1987)¹⁵³, finansal oranlar arasındaki ilişkinin zaman içerisinde istikrarsız oldukları konusunda kanıt bulmuş ve finansal oranların alternatif muhasebe

¹⁵¹ Aktaş, a.g.e., s.78.

¹⁵² Balcaen; Ooghe; a.g.e., p.25.

¹⁵³ Paul Barnes; "The Analysis and Use of Financial Ratios: A Review Article", Journal of Business Finance & Accounting, Vol. 14, No. 4, 1987, pp.449-461.

metodlarının kullanılmasına duyarlı olabileceğini belirtmiştir. Mensah (1984) ise veri istikrarsızlığının enflasyon, faiz oranı ve işletme hayat seyirinin aşamalarındaki değişikliklerden kaynaklanabileceğini ileri sürmüştür¹⁵⁴. Sonuç olarak, tahmin modelleri söz konusu probleme maruz kalmaktadırlar.

Durağan olmama ve veri istikrarsızlığı, finansal başarısızlık tahmin modellerinde ciddi sorunlar ortaya çıkarabilmektedir. İlk olarak, kurulan model, zayıf tahmin yeteneğine sahip olabilir. Böyle bir model, sonraki zaman dönemlerinden örnekler üzerinde uygulandığında performansı büyük ölçüde azalacaktır. Diğer bir ifadeyle, değişkenler arasındaki ilişkiler zaman içerisinde durağan olmadığında, model kestirim örneği üzerinde yüksek sınıflandırma doğruluğuna sahip olsa bile kestirim örneği dışındaki işletmelere uygulandığında daha kötü bir performans gösterebilir¹⁵⁵. Bu nedenle, oluşturulan modellerin sonraki dönemdeki yeni örnekler üzerinde test edilmesi son derece önemlidir. Literatürde, pek çok akademisyen bu hususta aynı görüşü paylaşmaktadır.

Veri istikrarsızlığı, modellerin özünde istikrarsız oldukları ya da zaman içerisinde sağlam olmadıkları anlamına gelmektedir. Öyle ki, geleneksel istatistiki yöntemlerle oluşturulan başarısızlık tahmin modelleri, daha yeni veriler üzerinde tekrar oluşturulduklarında, katsayılar genellikle değişiklik göstermektedirler. Sonuç olarak, tahmin modelleri özünde kararsızdırlar ve zamanla yeniden geliştirmeye gerek duyulabilmektedir. Bu nedenle, Keasey ve Watson (1991), tahmin yapılacak zaman döneminden çok önce oluşturulmuş eski modellerin faydalı olmadıklarını iddia etmektedirler¹⁵⁶. Bu bağlamda, başarısızlık tahmin modellerinin performansının düzenli zaman aralıklarıyla test edilmesi ve gerekliyse modellerin güncellenmesi uygun görülmektedir. Bir modelin güncellenmesi, modelde yer alan değişkenlerin ve katsayıların değiştirilmesini kapsayabileceği gibi sadece yeni kopuş değerlerinin hesaplanmasıyla da sınırlanabilir.

¹⁵⁴ Yaw M. Mensah; "An Examination of the Stationarity of Multivariate Bankruptcy Prediction Models: A Methodological Study", Journal of Accounting Research, Vol 22, No 1, Spring 1984, pp.383.

¹⁵⁵ Balcaen; Ooghe; a.g.e., p.25.

¹⁵⁶ Keasey; Watson; "Financial Distress Prediction Models: A Review of Their Usefulness", p.98.

Literatürde, veri istikrarsızlığıyla ilgili problemlerin üstesinden gelebilmek için bazı çalışmalar yapılmıştır. Bazı araştırmacılar, finansal oranların değişimlerine göre istikrarını ölçmüşler ve analizlerine bu ölçüleri de dahil etmişlerdir. Diğer bazı araştırmacılar ise veri istikrarsızlığı problemini azaltmak için başarısızlık tahmin modellerinde sektör oranlarını da kullanmışlardır. Finansal oranların enflasyondan arındırılmış değerlerini kullanmanın da modellerin tahmin performansını artıracığını öne süren çalışmalar bulunmaktadır¹⁵⁷.

Modellerin sonraki yıllarda tahmin amaçlı kullanılmasının dışında, model oluşturulurken farklı yıllardan verilerin kullanılması da değişkenler arası ilişkilerin zaman içerisinde istikrarlı olmasını gerektirmektedir. Finansal başarısızlık tahmini alanındaki çalışmaların büyük bir çoğunluğunda, model kurmada kullanılan başarısız işletmeler örneği toplanmış bir örnektir. Yani, farklı yıllarda başarısız olmuş işletmelerden oluşmaktadır. Toplanmış verilerin farklı makroekonomik koşullardan etkilendiği açık olmasına rağmen, genellikle tahmin modelleri temel ekonomik olayları dikkate almamaktadırlar. Tahmin modellerinde, dolaylı olarak modeldeki değişkenler arası ilişkilerin zaman içerisinde istikrarlı olduğu varsayılmaktadır. Diğer bir ifadeyle, söz konusu modellerde verilerin durağan ve istikrarlı olduğu varsayılmaktadır. Bununla birlikte, daha önce belirtildiği gibi uygulamada durağanlık varsayımının ihlal edilmesi muhtemeldir ve literatürde veri istikrarsızlığıyla ilgili pek çok kanıt bulunmaktadır. Sonuç olarak, toplanmış veriler üzerinde kurulan tahmin modelleri tutarsız katsayılara ve daha düşük doğruluk oranlarına sahip olabilir¹⁵⁸.

Toplanmış örneklere ilişkin eleştirilere karşın, farklı yıllardan verilerin toplanmasının modelin temsil yeteneğini artırmak açısından gerekli olduğu da iddia edilebilir. Çünkü, çok sınırlı bir zaman döneminden verilere dayalı olarak kurulan tahmin modelinin, farklı zaman dönemlerinden verilere uygulandığında zayıf tahmin sonuçlarına sahip olması muhtemeldir.

¹⁵⁷ Balcaen; Ooghe; a.g.e., p.26.

¹⁵⁸ A.g.e., p.27.

2.2.6. Hata Maliyetlerinin Etkisi

Mevcut finansal başarısızlık tahmin çalışmalarının çoğu, modelin tahmin yeteneğini ve performansını toplam hata oranlarını dikkate almak suretiyle değerlendirmektedir. Modelin başarısız bir işletmeyi başarılı olarak yanlış sınıflandırmasına 1. tip hata; başarılı bir işletmeyi başarısız olarak yanlış sınıflandırmasına ise 2. tip hata denilmektedir. Genellikle modeller bir işletmeyi % 90'dan daha fazla bir doğrulukla başarısız veya başarılı kategorilere sınıflandırabilmektedir. Ancak, 1. tip ve 2. tip hata maliyetlerinin birbirinden oldukça farklı olması muhtemeldir. Bu farklı maliyetler hesaba katılarak, verilen kararların daha etkin olması sağlanabilir.

1. tip ve 2. tip hataların başlıca maliyetleri, Altman (1982) tarafından tartışılmıştır. Altman 1. tip hata maliyetlerini şöyle sıralamaktadır¹⁵⁹:

- 1) İşletme yönetimi durumun ciddiyetini fark edemeyeceği için düzeltici önlemleri almada geç kalabilir.
- 2) Yatırımcılar olası bir tasfiye hakkında uyarı alamayacağı için yatırımlarının bir kısmını veya tamamını kaybedebilir.
- 3) Denetçiler itibar kaybıyla ve büyük cezalarla sonuçlanabilecek davalarla karşılaşabilirler.

Ancak, yapılan çalışmaların çoğunda bu husus ihmal edilerek, 1. tip hata maliyetlerinin 2. tip hata maliyetlerine eşit olduğu varsayılmaktadır. Büyüklüğü konusunda kesin kanıt bulunmama ile birlikte 1. tip hata maliyetinin 2. tip hata maliyetinden çok daha yüksek olduğu bilinmektedir.

1. tip ve 2. tip hata maliyetlerinin büyüklüğü konusunda kesin bir kanıt bulunmadığı için, genellikle çalışmalarda 1. tip hata maliyetinin 2. tip hata maliyetine oranı 100/1'den 1/1'e kadar değişen oranlarda dikkate alınmaktadır¹⁶⁰. Farklı oranlar için

¹⁵⁹ J. E. Boritz; J. Sun; "Predicting Going Concern Risks in Canada", School of Accountancy Working Paper, January 2004, Submitted to ASAC Conference, p.5.

¹⁶⁰ Anurag Agarwal; "Abductive Networks for Two-Group Classification: A Comparison with Neural Networks", The Journal of Applied Business Research, Vol. 15, No. 2, 1999, p.5.

farklı kopuş değerleri hesap edilerek, modeller değerlendirilmektedir. 1. tip hata maliyetinin 2. tip hata maliyetine oranı azaldıkça, optimal kopuş değeri artmaktadır.

Yukarıdaki yol, hata maliyetlerinin sabit olduğunu, yani başarısızlık olasılığı arttıkça değişmeyeceğini varsaymaktadır. Gerçekte ise başarısızlık olasılığı arttıkça, kredi alana yüklenen faiz oranının artması da muhtemeldir. Dolayısıyla, bir işletmenin kredi derecesi değiştikçe 1. tip hata – 2. tip hata maliyetleri arasındaki ilişki de değişmektedir¹⁶¹.

Kredi verenler açısından bakıldığında, 1. tip hata maliyeti anapara ve faiz kaybından oluşurken, 2. tip hatanın maliyeti ise sağlam bir müşteriye kredi vermemenin doğurduğu fırsat maliyetidir¹⁶².

Finansal başarısızlık tahmin çalışmalarında karşılaşılan sorunlar tabiki yukarıdaki anlatılanlarla sınırlı değildir. Modelin büyüklüğü, değişkenlerin gücünün belirlenmesi, sapma matrislerinin eşit olmaması gibi pek çok sorunu daha ilave etmek mümkündür. Burada söz konusu sorunların en önemlileri ele alınmaya çalışılmıştır.

¹⁶¹ Weiss; a.g.e., p.5.

¹⁶² Sudhir Nanda; Parag Pendharkar; “Linear Models for Minimizing Misclassification Costs in Bankruptcy Prediction”, International Journal of Intelligent Systems in Accounting, Finance & Management, Vol. 10, 2001, p.155.

ÜÇÜNCÜ BÖLÜM: GELENEKSEL İSTATİSTİKİ YÖNTEMLER VE YAPAY SİNİR AĞLARIYLA SANAYİ İŞLETMELERİNDE FİNANSAL BAŞARISIZLIĞIN TAHMİN EDİLMESİ

3.1. UYGULAMANIN AMACI

İşletmelerin finansal başarısızlıklarının, işletmeyle ilgili çeşitli gruplara olan maliyetlerinin yanı sıra sosyal maliyetlerinin de bulunduğu bilinen bir gerçektir. Bu nedenle, finansal başarısızlık tahminine yönelik olarak farklı yöntemleri kullanan çok sayıda model geliştirilmiştir. Her şartta ve her ortamda geçerli mükemmel bir modelin bulunmayışı, bu çabaları sürdürecektir.

Bugüne kadar yapılan çalışmalarda, finansal başarısızlığı tahmin edebilmek için çeşitli istatistikî yöntemlerden ve yapay zeka sistemlerinden yararlanılmıştır. Bunlar arasında, literatürde en yaygın olarak kullanılan, doğruluğu ve sağlamlığı konusunda kanıtlar bulunan yöntemler; diskriminant analizi, lojistik regresyon analizi ve yapay sinir ağlarıdır. Bu çalışmanın amacı, Türkiye'deki sanayi işletmeleri için finansal başarısızlık tahmin modeli geliştirmede bu üç yöntemin performansını, başarısızlıktan beş yıl öncesine kadar karşılaştırmaktır.

3.2. UYGULAMADA KULLANILAN YÖNTEMLER VE YAZILIMLAR

Finansal başarısızlığı tahmin edebilecek modeller kurulurken, diskriminant analizi, lojistik regresyon analizi ve yapay sinir ağı yöntemleri kullanılmıştır. Diskriminant ve lojistik regresyon modellerinin kurulmasında, SPSS 15.0 for Windows paket programından, yapay sinir ağı içinse NeuroSolutions 5.0 yazılımından yararlanılmıştır. Değişken sayısını azaltmak için, diskriminant analizi ve lojistik regresyon analizi uygulanırken aşamalı seçim (stepwise) prosedürü izlenmiştir.

Diğer çalışmalarla karşılaştırılabilir olması açısından, elde edilen modellerin performansları öncelikle “doğruluk”, “duyarlılık” ve “özgünlük” gibi klasik performans ölçülerine göre değerlendirilmiştir. Daha sonra, tüm kopuş değerlerini dikkate alarak daha rasyonel bir karşılaştırma yapan ROC eğrileri yardımıyla modellerin performansları karşılaştırılmıştır. ROC eğrilerinin oluşturulmasında MedCalc 9.2 paket programı kullanılmıştır.

3.3. UYGULAMA ÖRNEĞİ

Bu çalışmada, örnek olarak hisse senetleri İstanbul Menkul Kıymetler Borsasında (İ.M.K.B.) işlem gören sanayi işletmeleri kullanılmıştır. Bunun temel nedeni, Türkiye’de diğer işletmelerin verilerine ulaşmadaki zorluktur. Hisse senetleri borsada işlem gören işletmeler, bağımsız denetimden geçmiş finansal tablolarını düzenli olarak borsaya sunmak zorundadırlar. Borsaya sunulan bu bilgiler, yatırımcılar tarafından kullanılabilir durumdadır. İ.M.K.B.’nin web sayfasında şirketlerin 3, 6, 9 ve 12 aylık mali tabloları ve dipnotları sürekli güncellenerek, kullanıcıların hizmetine sunulmaktadır.

İ.M.K.B.’ye kote olmuş işletmeler üzerinde çalışmanın hem bazı avantajları hem de birtakım dezavantajları bulunmaktadır. Bu işletmelerle çalışmanın en önemli avantajları; finansal tablolarının S.P.K.’nin belirlediği standartta hazırlanmış tek tip tablolar olması ve bağımsız denetimden geçtiği için güvenilir bilgiler taşımasıdır. Bu şirketlerle çalışmanın en büyük dezavantajı ise işletme sayısının az olmasıdır. Sanayi işletmelerinin toplam sayısının yıllar itibariyle 200’ü geçmediği, bunun içinde en büyük yere sahip tekstil sektöründe bile 35 işletmenin yer aldığı düşünüldüğünde, sektörel bir başarısızlık tahmin modeli kurmak mümkün olmamaktadır. Dolayısıyla, birbirinden farklı özellikler gösterebilecek çeşitli sektörlerdeki işletmeler örneğe dahil edilmektedir.

Yukarıda bahsedilen nedenden dolayı, bu çalışmada da sektörel bir ayırım yapılamamıştır. Ancak, İ.M.K.B.’de işlem gören şirketlerden, mali kuruluşlar, holdingler, ticaret ve hizmet şirketleri çok farklı özellikler taşıdığı için örneklem dışı bırakılmış ve kapsama sadece sanayi şirketleri dahil edilmiştir.

1992-2004 yılları arasında, hisse senetleri İ.M.K.B.’de işlem görmüş ya da görmeye devam eden 203 sanayi şirketinin 12 aylık bilanço ve gelir tabloları, Microsoft Excel

programında standartlaştırılmıştır. Çünkü, İ.M.K.B.'nin web sayfasında yer alan mali tablolar, 1992-1997 dönemi için farklı, 1997 yılı sonrası için farklı bir formattadır. Tüm tablolar standart bir hale getirildikten sonra, herhangi bir zaman aralığını kapsayacak şekilde en az üst üste 5 yıllık döneme ait finansal tablosu bulunmayan işletmeler kapsam dışı bırakılmıştır.

Geriye kalan işletmeler arasından, aşağıdaki kriterler esas alınarak başarısız işletmeler tespit edilmiştir:

- İflas etmiş olmak,
- Borsada tahtası kapanmış olmak,
- Faaliyetlerini durdurmuş olmak,
- Üst üste 2 ya da daha fazla yıl zarar etmiş olmak.

Yukarıdaki kritere uyan işletmelerin iflas ettikleri yıl, tahtasının kapandığı yıl, faaliyetlerini durdurduğu yıl ya da üst üste zararların başladığı ilk yıl başarısızlık başlangıç yılı (t) olarak kabul edilmiştir. Finansal başarısızlık tahmin modelinin amacı, finansal başarısızlığı önceden tahmin etmektir. Bu nedenle, yukarıdaki kriterlere uyan işletmelerden, başarısızlığın başlangıcından önceki yıllarda yukarıdaki kriterleri taşımayarak, faaliyetlerini normal olarak sürdürürken başarısızlık içine giren şirketler, başarısız örnek grubuna dahil edilmiştir. Tüm yıllarda faaliyetlerini normal ve karlı olarak sürdüren şirketler ise başarılı örnek grubuna dahil edilmiştir.

Bu 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. Geriye kalan 163 işletmeden 75'i başarısız, 88'i ise başarılı işletme özelliklerini taşımaktadır. Her iki grubun örnek içerisinde eşit sayıda temsil edilmesini sağlamak amacıyla, tesadüfi olarak seçilen 13 başarılı işletme kapsam dışı bırakılmıştır. Dolayısıyla, uygulamada kullanılan örnek, yarısı başarısız, yarısı başarılı olmak üzere 150 sanayi işletmesinden oluşmaktadır. Çalışma kapsamına alınan işletmelerin listesi Ek-1'de yer almaktadır.

Finansal başarısızlık tahmin çalışmalarının çoğunda, aynı yıla ait yeterli sayıda veri bulunamaması nedeniyle, farklı yıllardan veriler kullanılmıştır. Bu durum, bu çalışma için de geçerlidir. Ancak, 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 yayınlanmıştır. Söz konusu tebliğ kapsamında yer alan şirketlerin, 01.01.2005 tarihini izleyen ilk ara mali tablolarından itibaren bu standartlara uymaları zorunlu tutulurken, dileyen şirketlere de 31.12.2003 tarihinde sona eren hesap döneminden itibaren, bu standartlara uygun olarak mali tablolarını hazırlayabilme olanağı tanınmıştır¹⁶³. Bu nedenle, farklı esaslara göre düzenlenmiş tablolardan kaynaklanabilecek sorunları ortadan kaldırmak için, finansal başarısızlık tahmin modelleri kurmada 2002 yılı ve öncesindeki veriler kullanılmıştır. Diğer bir ifadeyle, başarısızlık başlangıç yılı 2003 yılı dahil olmak üzere bu tarihe kadar olan işletmeler örneğe dahil edilmiş, 2004 yılı ve sonrasında başarısızlığa uğramış işletmeler kapsam dışında bırakılmıştır.

Farklı yıllardan verilerin kullanılması, mali tablolar üzerindeki enflasyon etkisini akla getirmektedir. Çalışmada, bağımsız değişkenler olarak finansal oranların kullanılmasının, bu etkiyi ortadan kaldırdığı varsayılmaktadır. Finansal oranların kullanılması, enflasyon etkisinin yanı sıra işletme büyüklüğü ve sektör farklılıkları gibi bazı önemli faktörlerin de kontrol altına alınmasını sağlamaktadır.

İstatistiki modeller kurulurken, genellikle örnek, kestirim seti ve kontrol seti olmak üzere iki alt kümeye ayrılmaktadır. Kestirim seti üzerinde model geliştirilmekte ve modelin performansı model kurma aşamasında kullanılmayan kontrol seti üzerinde test edilmektedir. Kontrol seti üzerindeki sonuçlar, modelin üzerinde kurulduğu örneğe özgü olup olmadığını, diğer bir ifadeyle modelin genelleştirme yeteneğini göstermektedir. Benzer şekilde, yapay sinir ağları da eğitim seti denen bir örnek alt kümesiyle eğitilmekte ve ağın genelleştirme yeteneği, ağın karmaşık ilişkileri öğrenirken görmediği test seti üzerinde ölçülmektedir. Yapay sinir ağlarında, bu iki örnek alt kümesinin dışında, ağın ezberlemesini ve yerel minimum tuzağına düşmesini önlemek

¹⁶³ http://www.spk.gov.tr/ofd/Guncel_Karar_Duyuru/UFRS_uygulama_esaslari_hakkinda.pdf

amacıyla onaylama seti adında bir örnek seti daha kullanılmaktadır. Bundan dolayı, çalışma kapsamına dahil edilecek başarısız ve başarılı işletmeler tespit edildikten sonra elde edilen örneklem, 3 alt kümeye ayrılmıştır. Bu alt kümelerin nasıl ayrılacağı konusunda kabul görmüş tek bir yol bulunmadığından, uygulamada farklı yöntemler kullanılmaktadır. Bu çalışmada, 150 işletmeden oluşan toplam örnek % 60'ı kestirim/egitim seti, % 20'si kontrol/test seti ve % 20'si onaylama seti olmak üzere alt kümelere ayrılmıştır. Bu alt kümelere yer alan şirketlerin listesi, Ek-1'de yer almaktadır. Dolayısıyla, 90 şirket modellerin oluşturulmasında kullanılırken, 30 şirket ise modellerin geçerliliğinin test edilmesi amacıyla kullanılmıştır. Geriye kalan 30 şirketten ise onaylama seti olarak sadece yapay sınır ağı modelleri kurmada yararlanılmıştır. Her üç veri setinde de başarılı ve başarısız şirketlerin sayısı birbirine eşittir.

3.4. BAĞIMSIZ DEĞİŞKENLERİN SEÇİMİ

Finansal başarısızlığı tahmin etmek için yapılan ampirik çalışmaların çoğunda, bağımsız değişken olarak kullanılacak oranlar, genellikle literatürde önemli olduğu kabul edilen ve yaygın olarak kullanılan oranlar arasından seçilmektedir. Bu çalışmada da aynı yöntem izlenerek belirlenen 26 finansal oran, 4 temel oran grubuna sınıflandırılarak aşağıda sunulmuştur. Söz konusu 26 finansal oran, işletmelerin 12 aylık bilanço ve gelir tabloları yardımıyla Ek-2 de yer alan formüller aracılığıyla hesaplanmıştır.

A) LİKİDİTE ORANLARI

X1: Cari Oran

X2: Asit-Test Oranı

X3: Nakit Oranı

X4: Stokların Toplam Varlıklara Oranı

X5: Kısa Vadeli Alacakların Toplam Varlıklara Oranı

B) FİNANSAL YAPI ORANLARI

X6: Finansal Kaldıraç Oranı

X7: Kısa Vadeli Yabancı Kaynakların Toplam Kaynaklara Oranı

X8: Uzun Vadeli Yabancı Kaynakların Toplam Kaynaklara Oranı

X9: Uzun Vadeli Yabancı Kaynakların Devamlı Sermayeye Oranı

X10: Duran Varlıkların Özsermayeye Oranı

X11: Dönen Varlıkların Toplam Varlıklara Oranı

C) FAALİYET ORANLARI

X12: Hazır Değerler Devir Hızı

X13: Stok Devir Hızı

X14: Alacak Devir Hızı

X15: Dönen Varlık Devir Hızı

X16: Duran Varlık Devir Hızı

X17: Özsermaye Devir Hızı

X18: Toplam Varlık Devir Hızı

D) KARLILIK ORANLARI

X19: Özsermayenin Karlılığı Oranı (Mali Rantabilite)

X20: Faiz ve Vergi Öncesi Karın Toplam Kaynaklara Oranı (Ekonomik Rantabilite)

X21: Toplam Varlıkların Karlılığı Oranı

X22: Faaliyet Kar Marjı

X23: Brüt Kar Marjı

X24: Net Kar Marjı

X25: Finansman Giderlerinin Net Satıřlara Oranı

X26: Finansman Giderlerini Karřılama Oranı

3.5. FİNANSAL BAŞARISIZLIK TAHMİNİ İÇİN KURULAN MODELLER

Literatürde, finansal başarısızlık tahmin modeli kurmada genellikle üç farklı yol izlendiđi görölmektedir. Bunlar:

- Başarısızlıktan önceki her yıl için farklı oran ve katsayılarından oluşan modeller kurmak,
- Başarısızlıktan önceki her yıl için aynı oranlardan fakat farklı katsayılarından oluşan modeller kurmak,
- Başarısızlıktan önceki tüm yıllar için kullanılabilcek tek bir model kurmak.

Bu çalışmada üçüncü yol tercih edilerek, başarısızlıktan önceki tüm yıllar için aynı model kullanılmıştır. Esas itibariyle, birinci ve ikinci seçeneđin daha yüksek sınıflandırma doğruluđuna sahip olması muhtemeldir. Eđer arařtırmanın amacı, finansal başarısızlıktan önceki yıllar itibariyle hangi oranların daha iyi göstergeler olduđunu tespit etmekse birinci yolu kullanmak daha uygundur. İkinci yol kullanılarak ise başarısızlıktan önceki yıllar için başarısızlık göstergesi olan oranların aynı olduđu, fakat başarısızlıđa yaklařtıkça katsayılarının deđiřeceđi varsayılmaktadır. Ancak amaç, birkaç yıl öncesinden finansal başarısızlıđı tahmin edebilecek bir model geliřtirmek olduđunda, üçüncü yol daha uygun görölmektedir. Bu çalışmanın amacı, finansal başarısızlık tahmini bağlamında çeřitli yöntemlerin performanslarının karřılařtırılması olduđundan üçüncü yol daha anlamlı bulunmuř ve her bir yöntem için geliřtirilen tek bir modelin başarısızlıktan 5 yıl öncesine kadar tahmin güçleri karřılařtırılmıştır. Modellerin kurulmasında, finansal başarısızlıđa yaklařtıkça belirtilerinin de daha fazla artacađı varsayılarak başarısızlıktan bir yıl önceki veriler kullanılmıştır.

Başarısızlıktan önceki tüm yıllar için tek bir modelin kullanılması, iřletmeyle ilgili kararlarını daha etkin olarak verebilmek için bu modellerden faydalanacak kiřiler için

de daha uygundur. Çünkü diğer durumda, bu modelleri kullanacak kişinin hangi modeli tercih etmesi gerektiği belli değildir. Zaten, işletmenin başarısız olacağı ve bu başarısızlıktan kaç yıl öncesinde bulunduğu bilinirse, böyle bir tahmin modeline de ihtiyaç duyulmayacağı açıktır.

3.5.1. Diskriminant Modeli

Başarısızlıktan bir yıl önceki veriler üzerinde SPSS 15.0 for Windows programı yardımıyla diskriminant modeli kurulmuştur. 26 finansal oran bağımsız değişken olarak programa sunulmuş, aşamalı seçim (stepwise) yöntemi yardımıyla 4 değişkenli bir diskriminant modeli elde edilmiştir. Diskriminant analizine ilişkin program çıktıları Ek-3'de yer almaktadır.

Diskriminant analizine ilişkin program çıktılarında yer alan özdeğer (eigenvalue), diskriminant analizinin ne kadar önemli olduğunu gösteren bir istatistiktir. Özdeğerin "0" olması, diskriminant analizinin herhangi bir ayırım gücü olmadığını gösterir. Özdeğerin bir üst sınırı olmamasına rağmen 0,40'dan büyük özdeğerler mükemmel sayılmaktadırlar¹⁶⁴. Bu çalışmada, özdeğerin 0,873 çıkması modelin ayırım gücüne sahip olduğunu göstermektedir. Elde edilen model aşağıdadır:

$$Z_i = - 0,176 - 0,672X_2 + 1,563X_{10} + 0,002X_{12} - 9,262X_{24}$$

Burada;

Z_i ; Diskriminant Skoru,

X_2 ; Asit-Test Oranı,

X_{10} ; Duran Varlıkların Özsermayeye Oranı,

X_{12} ; Hazır Değerler Devir Hızı,

X_{24} ; Net Kar Marjıdır.

¹⁶⁴ Murat Atan; Risk Yönetimi ve Türk Bankacılık Sektöründe Uygulama, Doktora Tezi, Gazi Üniversitesi, Ankara 2002, p.138.

Bu model yardımıyla değerlendirme yapabilmek için, durumu tahmin edilmeye çalışılan işletmenin yukarıdaki 4 finansal oranı hesaplanarak, modelde yerine konulur. İşletme için hesaplanan Z değeri, başarısız ve başarılı işletmeleri ayırtetmede kullanılacak kopuş değeri Z^* ile karşılaştırılır. Yanlış sınıflandırma maliyetlerinin ve grupların önsel dağılımlarının eşit varsayılması durumunda, kopuş değeri grup merkezlerinin ortalamasıdır. Yukarıdaki diskriminant fonksiyonu için elde edilen grup merkezleri, başarısız işletmeler için 0,924, başarılı işletmeler içinse -0,924'tür. İşletmeleri diskriminant değerlerine göre gruplara sınıflandırmada kullanılacak kopuş değeri ise bu iki grup merkezinin ortalaması olan 0'dır. Dolayısıyla elde edilen diskriminant skoru 0'dan küçük olan işletmeler başarılı, 0'dan büyük olan işletmeler ise başarısız olarak sınıflandırılacaktır.

3.5.2. Lojistik Regresyon Modeli

Başarısızlıktan bir yıl önceki veriler üzerinde, SPSS 15.0 for Windows programı yardımıyla lojistik regresyon modeli kurulmuştur. 26 finansal oran bağımsız değişken olarak programa sunulmuş, aşamalı seçim (stepwise) yöntemi yardımıyla 3 değişkenli bir lojistik regresyon modeli elde edilmiştir. Lojistik regresyon analizine ilişkin program çıktıları Ek-4'de yer almaktadır. Elde edilen model:

$$Z_i = 3,531 - 5,221X_{10} - 0,007X_{12} + 17,932X_{24}$$

Burada;

Z_i ; Lojistik regresyon fonksiyonu,

X_{10} ; Duran Varlıkların Özsermayeye Oranı,

X_{12} ; Hazır Değerler Devir Hızı,

X_{24} ; Net Kar Marjıdır.

Bu model yardımıyla bir işletmenin durumunu tahmin edebilmek için, öncelikle işletmenin modelde yer alan üç finansal oranı hesaplanarak modelde yerine konulur. İşletmenin hesaplanan Z değeri, aşağıdaki formül yardımıyla işletmenin başarılı olma olasılığı şekline dönüştürülür.

$$P_i = 1/(1+e^{-Z_i})$$

Elde edilen olasılık, 0,50'den büyükse işletme başarılı olarak, diğer durumda ise başarısız olarak sınıflandırılır.

3.5.3. Yapay Sinir Ağı Modeli

Yapay sinir ağı modelinin kurulmasında, NeuroSolutions 5.0 bilgisayar yazılımından yararlanılmıştır. Daha önce de belirtildiği gibi, uygun yapay sinir ağı mimarisinin belirlenmesinde yaygın olarak deneme yanılma yöntemi kullanılmakta ve çok sayıda test yapılmaktadır. Bu kapsamda gizli katman sayısı, gizli katmanlardaki düğüm sayısı, öğrenme oranı, momentum terimi, aktivasyon fonksiyonu, devir sayısı gibi parametrelerin çeşitli kombinasyonları denenerek, gerek eğitim seti üzerinde gerekse test seti üzerinde daha iyi performans gösteren ağ saptanmıştır. Ağların eğitiminde aşırı uygunluk ve yerel minimum problemlerinden sakınmak için onaylama seti de kullanılmıştır. Ağların eğitimi başarısızlıktan bir yıl önceki veriler üzerinde gerçekleştirilmiştir.

Önemli ilişkileri vurgulamak, yapay sinir ağı öğrenmesini kolaylaştırmak, eğitim algoritmasının gereksinimlerini karşılamak ve hesaplama problemlerinden kaçınmak amacıyla tek düze veriler yaratmak için, sıklıkla verilerin ön işleme tabi tutulması tavsiye edilmektedir. Bununla birlikte, verilerin ön işleme tabi tutulmasının ağın öğrenmesi ve genelleştirmesi üzerindeki gerekliliği ve etkisi henüz genel kabul görmemiştir¹⁶⁵. Öyleki verileri ön işleme tabi tutmanın gerekli olmadığını savunanların ve uygulamada ön işleme başvurmayanların sayısı azımsanamayacak derecededir. Bu nedenle bu çalışmada da veriler herhangi bir ön işleme tabi tutulmamıştır.


Deneme-yanılma yöntemi sonunda belirlenen en iyi performansa sahip yapay sinir ağının özellikleri, aşağıda Tablo 3.1.'de yer almaktadır.

¹⁶⁵ G. Peter Zhang; Neural Networks in Business Forecasting, Idea Group Publishing, 2004, 350p.

Tablo 3.1. En İyi Performansa Sahip Yapay Sinir Ağının Özellikleri

Ağın Türü:	Çok Katmanlı Perseptron
Öğrenme Algoritması:	Geri Yayılım
Öğrenme Kuralı:	Momentum
Giriş Katmanındaki Düğüm Sayısı:	26
Gizli Katman Sayısı:	2
1. Gizli Katmandaki Düğüm Sayısı:	10
2. Gizli Katmandaki Düğüm Sayısı:	5
Çıkış Katmanındaki Düğüm Sayısı:	1
Momentum:	0,80
Öğrenme Oranı:	0,01
Devir Sayısı:	30.000
Aktivasyon Fonksiyonu:	Hiperbolik Tanjant

En iyi performansa sahip söz konusu yapay sinir ağı Şekil 3.1.'deki gibidir.



Şekil 3.1. En İyi Performansa Sahip Yapay Sinir Ağının Mimarisi

3.6. GELENEKSEL PERFORMANS ÖLÇÜLERİ YARDIMIYLA TAHMİN MODELLERİNİN PERFORMANSLARININ DEĞERLENDİRİLMESİ

3.6.1. Geleneksel Performans Ölçüleri

Tahmin testlerinin denetimi, gerçek başarılı ve başarısız işletmeler üzerindeki tahmin testi sonucuna göre yapılır. Bir tahmin testinin değerlendirilmesi, Tablo 3.2.’deki sınıflandırma matrisi çerçevesinde; üstte gerçek sonuçlar yanda ise tahmin sonuçları verilerek yapılmaktadır¹⁶⁶. Bundan sonraki açıklamalarda aşağıda verilen simgeler kullanılmaktadır.

Tablo 3.2. Genel Sınıflandırma Matrisi

		Gerçek Durum		
		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 açısından; “A” gözü gerçek duruma uygun olarak modelin de başarısız olarak tahmin ettiği işletmeler, gerçek pozitifler (GP) olarak adlandırılırlar. Buna karşılık C gözündeki olgular, gerçekte başarısız olup modelin başarılı olarak tahmin ettiği yani yanlış negatif (YN) işletmelerdir. Bu çerçevede testin geneli için geleneksel performans ölçüleri aşağıda anlatılmaktadır.

1) Duyarlılık (Sensitivity): Testin, gerçek başarısız işletmeler içinden başarısızları ayırma yeteneğidir.

$$\text{Duyarlılık} = A / (A+C) = GP / (GP+YN)$$

Gerçekte başarılı olan işletmeler açısından; “D” gözü gerçek duruma uygun olarak tahmin modelinin de başarılı olarak tahmin ettiği gerçek negatif (GN) işletmelerdir. “B”

¹⁶⁶ Ahmet Dirican; “Tanı Testi Performanslarının Değerlendirilmesi ve Kıyaslanması”, Cerrahpaşa Tıp Dergisi, Cilt 32, Sayı 1, 2001, s.26.

gözü ise gerçekte başarılı oldukları halde model tarafından başarısız olarak sınıflandırılan yanlış pozitif (YP) işletmelerdir.

2) Özgüllük (Specificity): Modelin gerçek başarılı işletmeler arasından başarılı olanları ayırma yeteneğidir.

$$\text{Özgüllük} = D/(D+B) = GN/(GN+YP)$$

Duyarlılık ve özgüllük oranlarının tersi olarak, modelin hatalı yargıları da hesaplanabilir.

3) Yanlış Negatif Oranı: Gerçek başarısız işletmeler içinden modelin hatalı olarak başarılı dediği işletmelerin oranıdır.

$$YN = 1 - \text{Duyarlılık} = C/(A+C) = YN/(YN+GP)$$

Modelin hatalı olarak başarısız bulduğu işletmelerin oranı da yanlış pozitif oranı adını alır.

4) Yanlış Pozitif Oranı: Gerçek başarılı işletmeler içinde, modelin hatalı olarak başarısız dediği işletmelerin oranıdır.

$$YP = 1 - \text{Özgüllük} = B/B+D = YP/(YP+GN)$$

5) Doğruluk (Accuracy): Modelin toplam doğru tahmin oranına “doğruluk” denir.

$$\text{Doğruluk} = (A+D) / (A+B+C+D) = (GP+GN) / (GP+YP+YN+GN)$$

Doğruluk oranı veya doğru sınıflandırma oranı, doğru olarak tahmin edilen tüm işletmelerin (başarısız ve başarılı) yüzdesini veren ve en yaygın olarak kullanılan performans ölçüsüdür.

3.6.2. Tahmin Modellerinin Performansları

Çalışmada kullanılan her üç yöntemin performansını değerlendirmek için izlenen yol aşağıda anlatılmıştır.

Kestirim/eğitim setinde ve kontrol/test setinde yer alan işletmelerin, başarısızlıktan 5 yıl öncesine kadar ilgili 4 finansal oranı, elde edilen diskriminant fonksiyonunda yerine

konularak diskriminant deęerleri hesaplanmıřtır. Daha sonra, yanlış sınıflandırma maliyetlerinin birbirine eřit olduęu varsayımı altında, “0” kopuř deęeri esas alınarak diskriminant deęeri “0” dan küçük olan iřletmeler “bařarılı”, büyük olan iřletmeler ise “bařarısız” olarak sınıflandırılmıřtır. Bařarısızlıktan 5 yıl öncesine kadar tüm iřletmeler için hesaplanan diskriminant deęerleri ve modelin tahmini Ek-5 - Ek-9’da yer almaktadır.

Lojistik regresyon modelinin sınıflandırma performansını görebilmek için, kestirim/eęitim setinde ve kontrol/test setindeki tüm iřletmelerin ilgili 3 finansal oranı, elde edilen lojistik regresyon modelinde yerine konularak skorları hesaplanmıřtır. Daha sonra bu deęerler, ihtimaller oranı kullanılarak iřletmenin bařarılı olma olasılıęı řekline dönüřtürülmüřtür. Yanlış sınıflandırma maliyetlerinin birbirine eřit olduęu varsayılarak, “0,50” kopuř deęerine göre iřletmeler sınıflara atanmıřtır. Buna göre, ihtimaller oranı “0,50”den büyük olan iřletmeler “bařarılı”, küçük olan iřletmeler ise “bařarısız” olarak sınıflandırılmıřtır. Çalışma kapsamındaki iřletmeler için hesaplanmış ihtimaller oranları ve modelin tahmini Ek-5 - Ek-9’da yer almaktadır.

Yapay sinir aęı yaklařımında ise elde edilen optimum performansa sahip aę, eęitildikten sonra kullanılan bilgisayar programında kaydedilmiřtir. Daha sonra, bařarısızlıktan 5 yıl öncesine kadar iřletmelerin finansal oranları, kaydedilmiş olan aęa sunularak çıktıları elde edilmiřtir. Elde edilen aę çıktıları, yine yanlış sınıflandırma maliyetlerinin eřit olduęu varsayımı altında, “0,50” kopuř deęeri esas alınarak gruplara sınıflandırılmıřtır. Buna göre, aę çıktısı “0,50” den büyük iřletmeler “bařarılı”, küçük olan iřletmeler ise “bařarısız” olarak sınıflandırılmıřlardır. İřletmeler için aę çıktıları ve tahminler Ek-5 – Ek-9’da yer almaktadır.

3.6.2.1. Bařarısızlıktan Bir Yıl Öncesi İçin Tahmin Modellerinin Performansları

Diskriminant modeli, lojistik regresyon modeli ve yapay sinir aęının, modellerin de üzerinde geliřtirildięi kestirim/eęitim seti için bařarısızlıktan bir yıl öncesindeki sınıflandırma doęrulukları Tablo 3.3’de sunulmuřtur.

Tablo 3.3. Kestirim/Eđitim Seti İin Sınıflandırma Matrisi (t-1 Dönemi)

DİSKRİMİNANT MODELİ			
		Gerçek Grup	
		<u>Başarısız İşletmeler</u>	<u>Başarılı İşletmeler</u>
Tahmin Edilen Grup	<u>Başarısız İşletmeler</u>	36 % 80	8 % 17,8
	<u>Başarılı İşletmeler</u>	9 % 20	37 % 82,2
Toplam		45	45
Toplam Sınıflandırma Doğruluđu = $(36+37)/90 = \% 81,1$			
LOJİSTİK REGRESYON MODELİ			
		Gerçek Grup	
		<u>Başarısız İşletmeler</u>	<u>Başarılı İşletmeler</u>
Tahmin Edilen Grup	<u>Başarısız İşletmeler</u>	35 % 77,8	7 % 15,6
	<u>Başarılı İşletmeler</u>	10 % 22,2	38 % 84,4
Toplam		45	45
Toplam Sınıflandırma Doğruluđu = $(35+38)/90 = \% 81,1$			
YAPAY SİNİR AđI MODELİ			
		Gerçek Grup	
		<u>Başarısız İşletmeler</u>	<u>Başarılı İşletmeler</u>
Tahmin Edilen Grup	<u>Başarısız İşletmeler</u>	43 % 95,6	1 % 2,2
	<u>Başarılı İşletmeler</u>	2 % 4,4	44 % 97,8
Toplam		45	45
Toplam Sınıflandırma Doğruluđu = $(43+44)/90 = \% 96,7$			

Diskriminant modeli, başarısızlıktan bir yıl öncesinde başarısız işletmelerin % 80'ini, başarılı işletmelerin ise % 82,2'sini doğru olarak sınıflandırmıştır. Model, gerçekte başarısız oldukları halde 9 işletmeyi başarılı (1. tip hata); gerçekte başarılı olan 8 işletmeyi ise başarısız olarak (2. tip hata) yanlış sınıflandırmıştır. Dolayısıyla modelin 1. tip hata oranı % 20; 2. tip hata oranı ise % 17,8'dir. Modelin toplam sınıflandırma doğruluđu ise % 81,1'dir.

Lojistik regresyon modeli, başarısızlıktan bir yıl önce başarısız işletmeler için % 77,8; başarılı işletmeler için % 84,4 oranında doğru tahminde bulunmuştur. Modelin bir yıl

önceden toplam sınıflandırma doğruluğu ise diskriminant modelinkiyle aynıdır ve % 81,1'dir.

Yapay sinir ağı ise 45 başarısız işletmeden 43'ünü (% 95,6); 45 başarılı işletmeden ise 44'ünü (% 97,8) doğru olarak sınıflandırmayı başarmıştır. Yapay sinir ağı, % 96,7 oranında yüksek bir toplam sınıflandırma doğruluğuna sahiptir. Ancak, bu yüksek tahmin gücü ilk bakışta ihtiyatla karşılanmalıdır. Çünkü yapay sinir ağında, eğitim verilerindeki hata istenen düzeye gelinceye kadar eğitim sürmektedir. Bundan dolayı, ağın eğitiminde kullanılmayan test verileri üzerindeki performans da dikkate alınarak değerlendirme yapılmalıdır.

Başarısızlıktan bir yıl öncesinde yukarıda bahsedilen nedenden dolayı en iyi performansa sahip yöntem yapay sinir ağıdır. Gerek başarılı işletmeleri, gerekse başarısız işletmeleri geleneksel istatistiki yöntemlerin üzerinde bir doğrulukla tahmin edebilmektedir. Diskriminant modeli, lojistik regresyon modeline kıyasla başarısız işletmeleri daha doğru tahmin etmekle birlikte, toplam sınıflandırma doğruluğu açısından iki istatistiki yöntem arasında fark bulunmamaktadır.

Geliştirilen modellerin, sadece üzerinde geliştirildikleri verilere özgü olup olmadığını, diğer bir ifadeyle modellerin genelleştirilebilme yeteneğine sahip olup olmadığını araştırmak için, daha önce ayrılan 30 işletmelik kontrol/test seti üzerinde modellerin performansları ölçülmüştür. Sonuçlar Tablo 3.4'de yer almaktadır.

Tablo 3.4. Kontrol/Test Seti İçin Sınıflandırma Matrisi (t-1 Dönemi)

DİSKRİMİNANT MODELİ			
		Gerçek Grup	
		Başarısız İşletmeler	Başarılı İşletmeler
Tahmin Edilen Grup	Başarısız İşletmeler	11 % 73,3	3 % 20
	Başarılı İşletmeler	4 % 26,7	12 % 80
Toplam		15	15
Toplam Sınıflandırma Doğruluğu = $(11+12)/30 = \% 76,7$			

Tablo 3.4. Devamı

LOJİSTİK REGRESYON MODELİ			
		Gerçek Grup	
		<u>Başarısız İşletmeler</u>	<u>Başarılı İşletmeler</u>
Tahmin Edilen Grup	<u>Başarısız İşletmeler</u>	11 % 73,3	3 % 20
	<u>Başarılı İşletmeler</u>	4 % 26,7	12 % 80
Toplam		15	15
Toplam Sınıflandırma Doğruluğu = $(11+12)/30 = \% 76,7$			
YAPAY SİNİR AĞI MODELİ			
		Gerçek Grup	
		<u>Başarısız İşletmeler</u>	<u>Başarılı İşletmeler</u>
Tahmin Edilen Grup	<u>Başarısız İşletmeler</u>	14 % 93,3	2 % 13,3
	<u>Başarılı İşletmeler</u>	1 % 6,7	13 % 86,7
Toplam		15	15
Toplam Sınıflandırma Doğruluğu = $(14+13)/30 = \% 90$			

Tablodan görüldüğü üzere diskriminant modeli ve lojistik regresyon modeli, kontrol/ test seti üzerinde aynı performansı sergilemişlerdir. Her iki model de başarısız işletmeleri % 73,3; başarılı işletmeleri ise % 80 oranında doğru olarak sınıflandırmışlardır. Modellerin toplam sınıflandırma doğruluğu ise % 76,7'dir.

Yapay sinir ağı ise 15 başarısız işletmenin 14'ünü; 15 başarılı işletmenin ise 13'ünü doğru olarak sınıflandırarak, başarısız işletmeler için % 93,3; başarılı işletmeler içinse % 86,7 doğruluk elde etmiştir. Yapay sinir ağının toplam sınıflandırma doğruluğu ise % 90 olarak gerçekleşmiştir.

Başarısızlıktan bir yıl öncesinde yapay sinir ağının performansının, diğer iki istatistiki modelden çok daha iyi olduğu söylenebilir. Özellikle, ağın eğitimi esnasında hiç görmediği veriler üzerinde bu denli doğru tahmin yapabilmesi kayda değerdir.

3.6.2.2. Başarısızlıktan İki Yıl Öncesi İçin Tahmin Modellerinin Performansları

Finansal başarısızlığı tahmin edebilmek için kurulmuş olan üç modelin, başarısızlıktan iki yıl öncesi için kestirim/eğitim seti üzerindeki performansları aşağıda Tablo 3.5’de sunulmuştur.

Tablo 3.5. Kestirim/Eğitim Seti İçin Sınıflandırma Matrisi (t-2 Dönemi)

DİSKRİMİNANT MODELİ			
		Gerçek Grup	
		<u>Başarısız İşletmeler</u>	<u>Başarılı İşletmeler</u>
Tahmin Edilen Grup	<u>Başarısız İşletmeler</u>	25 % 55,6	17 % 37,8
	<u>Başarılı İşletmeler</u>	20 % 44,4	28 % 62,2
Toplam		45	45
Toplam Sınıflandırma Doğruluğu = (25+28)/90 = % 58,9			
LOJİSTİK REGRESYON MODELİ			
		Gerçek Grup	
		<u>Başarısız İşletmeler</u>	<u>Başarılı İşletmeler</u>
Tahmin Edilen Grup	<u>Başarısız İşletmeler</u>	27 % 60	14 % 31,1
	<u>Başarılı İşletmeler</u>	18 % 40	31 % 68,9
Toplam		45	45
Toplam Sınıflandırma Doğruluğu = (27+31)/90 = % 64,4			
YAPAY SİNİR AĞI MODELİ			
		Gerçek Grup	
		<u>Başarısız İşletmeler</u>	<u>Başarılı İşletmeler</u>
Tahmin Edilen Grup	<u>Başarısız İşletmeler</u>	32 % 71,1	12 % 26,7
	<u>Başarılı İşletmeler</u>	13 % 28,9	33 % 73,3
Toplam		45	45
Toplam Sınıflandırma Doğruluğu = (32+33)/90 = % 72,2			

Diskriminant modeli, başarısız işletmeleri % 55,6; başarılı işletmeleri ise % 62,2 doğrulukla iki yıl öncesinden doğru olarak sınıflandırmıştır. Toplam sınıflandırma

doğruluğu da % 58,9 olarak gerçekleşmiştir. Bu, diskriminant analizinin bir yıl öncesi için performansından oldukça düşüktür.

Lojistik regresyon modeli ise başarısız işletmeler için % 60; başarılı işletmeler içinse % 68,9 oranında sınıflandırma doğruluğu göstermiştir. Toplam sınıflandırma doğruluğu ise % 64,4'tür. Lojistik regresyon modelinin performansı da bir önceki yıl performansından daha düşüktür.

Yapay sinir ağı modeli ise 45 başarısız işletmenin 32'sini (% 71,1) doğru sınıflandırırken, 45 başarılı işletmeden de 33'ünü (% 73,3) doğru sınıflandırmıştır. Yapay sinir ağının toplam sınıflandırma doğruluğu da iki yıl öncesi için iyi sayılabilecek düzeyde % 72,2 olarak gerçekleşmiştir.

Başarısızlıktan 2 yıl öncesinde de yapay sinir ağlarının, geleneksel istatistiki modellere kıyasla daha yüksek performansını devam ettirdiği görülmektedir. İstatistiki yöntemler arasında ise lojistik regresyon modeli, başarısızlıktan iki yıl öncesinde diskriminant modelinden daha iyi tahminlerde bulunmuştur.

Başarısızlıktan iki yıl öncesi için modellerin kontrol/test seti üzerindeki performansları Tablo 3.6.'da yer almaktadır.

Tablo 3.6. Kontrol/Test Seti İçin Sınıflandırma Matrisi (t-2 Dönemi)

DİSKRİMİNANT MODELİ			
		Gerçek Grup	
		<u>Başarısız İşletmeler</u>	<u>Başarılı İşletmeler</u>
Tahmin Edilen Grup	<u>Başarısız İşletmeler</u>	10 % 66,7	5 % 33,3
	<u>Başarılı İşletmeler</u>	5 % 33,3	10 % 66,7
Toplam		15	15
Toplam Sınıflandırma Doğruluğu = (10+10)/30 = % 66,7			

Tablo 3.6. Devamı

LOJİSTİK REGRESYON MODELİ			
		Gerçek Grup	
		<u>Başarısız İşletmeler</u>	<u>Başarılı İşletmeler</u>
Tahmin Edilen Grup	<u>Başarısız İşletmeler</u>	12 % 80	5 % 33,3
	<u>Başarılı İşletmeler</u>	3 % 20	10 % 66,7
Toplam		15	15
Toplam Sınıflandırma Doğruluğu = $(12+10)/30 = \% 73,3$			
YAPAY SİNİR AĞI MODELİ			
		Gerçek Grup	
		<u>Başarısız İşletmeler</u>	<u>Başarılı İşletmeler</u>
Tahmin Edilen Grup	<u>Başarısız İşletmeler</u>	13 % 86,7	2 % 13,3
	<u>Başarılı İşletmeler</u>	2 % 13,3	13 % 86,7
Toplam		15	15
Toplam Sınıflandırma Doğruluğu = $(13+13)/30 = \% 86,7$			

Diskriminant modeli, kontrol setinde bulunan başarısız ve başarılı işletmeleri aynı oranda % 66,7 doğrulukla tahmin etmiştir. Dolayısıyla, toplam 30 işletmeden 20'sini doğru olarak tahmin eden diskriminant modelinin toplam sınıflandırma doğruluğu da % 66,7'dir.

Lojistik regresyon modeli ise kontrol seti üzerindeki başarısız işletmeler için % 80; başarılı işletmeler içinse % 66,7 doğru sınıflandırma performansına sahiptir. Lojistik regresyon modelinin iki yıl öncesi için toplam sınıflandırma doğruluğu ise % 73,3'tür.

Yapay sinir ağı modeli, başarısız ve başarılı işletmeleri tahmin etmede aynı başarıyı göstererek, % 86,7 toplam sınıflandırma doğruluğuna sahip olmuştur. Bu doğruluk oranının başarısızlıktan iki yıl öncesi için iyi olduğu söylenebilir.

3.6.2.3. Başarısızlıktan Üç Yıl Öncesi İçin Tahmin Modellerinin Performansları

Modellerin, üç yıl önceden işletmelerin durumunu tahmine yönelik performans sonuçları kestirim/egitim seti ve kontrol/test seti için ayrı ayrı aşağıdaki tablolarda sunulmuştur.

Tablo 3.7. Kestirim/Eğitim Seti İçin Sınıflandırma Matrisi (t-3 Dönemi)

DİSKRİMİNANT MODELİ			
		Gerçek Grup	
		<u>Başarısız İşletmeler</u>	<u>Başarılı İşletmeler</u>
Tahmin Edilen Grup	<u>Başarısız İşletmeler</u>	21 % 48,8	12 % 26,7
	<u>Başarılı İşletmeler</u>	22 % 51,2	33 % 73,3
Toplam		43	45
Toplam Sınıflandırma Doğruluğu = $(21+33)/88 = \% 61,4$			
LOJİSTİK REGRESYON MODELİ			
		Gerçek Grup	
		<u>Başarısız İşletmeler</u>	<u>Başarılı İşletmeler</u>
Tahmin Edilen Grup	<u>Başarısız İşletmeler</u>	22 % 51,2	11 % 24,4
	<u>Başarılı İşletmeler</u>	21 % 48,8	34 % 75,6
Toplam		43	45
Toplam Sınıflandırma Doğruluğu = $(22+34)/88 = \% 63,6$			
YAPAY SİNİR AĞI MODELİ			
		Gerçek Grup	
		<u>Başarısız İşletmeler</u>	<u>Başarılı İşletmeler</u>
Tahmin Edilen Grup	<u>Başarısız İşletmeler</u>	23 % 53,5	20 % 44,4
	<u>Başarılı İşletmeler</u>	20 % 46,5	25 % 55,6
Toplam		43	45
Toplam Sınıflandırma Doğruluğu = $(23+25)/88 = \% 54,5$			

Diskriminant modelinin, başarısızlıktan önceki üçüncü yılda başarısız işletmeleri % 48,8; başarılı işletmeleri ise % 73,3 oranında doğru tahmin edebildiği görülmektedir. Diskriminant modelinin toplam sınıflandırma doğruluğu, % 61,4'tür. Toplam

sınıflandırma doğruluğu bir önceki yıldan daha iyi olmasına rağmen, modelin başarısız işletmelerin % 51,2'sini yanlış şekilde başarılı olarak sınıflandırması, modeli kullanacak karar vericiler açısından oldukça sakıncalıdır. Çünkü daha önce de bahsedildiği gibi, 1. tip hata maliyeti, 2. tip hata maliyetinden çok daha yüksektir.

Lojistik regresyon modeli, başarısızlıktan üç yıl öncesinde başarısız işletmeleri % 51,2; başarılı işletmeleri ise % 75,6 doğrulukla tahmin etmiştir. Modelin üç yıl öncesinde tahmin doğruluğu da % 63,6'dır. Lojistik regresyon modeli de yüksek oranda 1. tip hata oranına sahiptir. Buna rağmen, 1. tip hata oranının % 50'nin altında olması modelin, hiçbir araç kullanmadan şansa dayalı olarak işletmeleri gruplara ayırmaktan daha iyi olduğu anlamına gelebilir.

Yapay sinir ağı modeli, başarısız işletmeleri % 53,5; başarılı işletmeleri ise % 55,6 oranında üç yıl öncesinden doğru olarak sınıflandırabilmiştir. Söz konusu modelin toplam sınıflandırma doğruluğu, % 54,5'tir. Üç yıl gibi uzun sayılabilecek bir süre öncesi için % 50'nin üzerinde tahmin doğruluğu, hiçbir araç kullanmadan tahmin yapmaktan daha iyi olarak değerlendirilebilir.

Başarısızlıktan üç yıl öncesi için toplam sınıflandırma doğruluğu açısından en iyi performansa sahip model lojistik regresyon modelidir. Ancak, başarısız işletmeleri doğru sınıflandırmada yapay sinir ağlarının diğer iki modelden daha başarılı olduğu gözardı edilmemelidir. Çünkü, daha öncede belirtildiği gibi 1. tip hata maliyeti, 2. tip hata maliyetinden çok daha yüksektir.

Üç yıl önceden kontrol/test seti üzerindeki performanslar Tablo 3.8.'de yer almaktadır.

Tablo 3.8. Kontrol/Test Seti İçin Sınıflandırma Matrisi (t-3 Dönemi)

DİSKRİMİNANT MODELİ			
		Gerçek Grup	
		<u>Başarısız İşletmeler</u>	<u>Başarılı İşletmeler</u>
Tahmin Edilen Grup	<u>Başarısız İşletmeler</u>	8 % 53,3	4 % 26,7
	<u>Başarılı İşletmeler</u>	7 % 46,7	11 % 73,3
Toplam		15	15
Toplam Sınıflandırma Doğruluğu = $(8+11)/30 = \% 63,3$			

Tablo 3.8. Devamı

LOJİSTİK REGRESYON MODELİ			
		Gerçek Grup	
		<u>Başarısız İşletmeler</u>	<u>Başarılı İşletmeler</u>
Tahmin Edilen Grup	<u>Başarısız İşletmeler</u>	8 % 53,3	3 % 20
	<u>Başarılı İşletmeler</u>	7 % 46,7	12 % 80
Toplam		15	15
Toplam Sınıflandırma Doğruluğu = $(8+12)/30 = \% 66,7$			
YAPAY SİNİR AĞI MODELİ			
		Gerçek Grup	
		<u>Başarısız İşletmeler</u>	<u>Başarılı İşletmeler</u>
Tahmin Edilen Grup	<u>Başarısız İşletmeler</u>	10 % 66,7	3 % 20
	<u>Başarılı İşletmeler</u>	5 % 33,3	12 % 80
Toplam		15	15
Toplam Sınıflandırma Doğruluğu = $(10+12)/30 = \% 73,3$			

Diskriminant modeli, kontrol/test seti üzerindeki 15 başarısız işletmeden 8'ini; 15 başarılı işletmedense 11'ini doğru sınıflandırarak, başarısız işletmeler için % 53,3; başarılı işletmeler için % 73,3 sınıflandırma doğruluğuna sahip olmuştur. Modelin tüm işletmeleri doğru sınıflandırma doğruluğu ise % 63,3'tür.

Lojistik regresyon modeli, kontrol/test setindeki başarısız işletmelerden % 53,3'ünü; başarılı işletmelerden % 80'ini doğru olarak sınıflandırmıştır. Modelin toplam sınıflandırma doğruluğu ise % 66,7 olarak gerçekleşmiştir.

Yapay sinir ağı modeli toplam 30 işletmeden 22'sini doğru olarak sınıflandırmayı başarmış ve % 73,3 toplam sınıflandırma doğruluğu elde etmiştir. Ağın başarısız işletmeleri doğru sınıflandırma oranı % 66,7; başarılı işletmeleri doğru sınıflandırma oranı ise % 80'dir.

Başarısızlıktan üç yıl öncesi için kontrol/test seti üzerinde en iyi performansa sahip model yapay sinir ağıdır. Ayrıca, lojistik regresyon modelinin az da olsa diskriminant analizinden daha doğru tahmin yapabildiği görülmüştür.

3.6.2.4. Başarısızlıktan Dört Yıl Öncesi İçin Tahmin Modellerinin Performansları

Aşağıda Tablo 3.9.'da her üç modelin kestirim/egitim seti üzerindeki, dört yıl önceden işletmenin durumunu tahmin etmeye yönelik performansları yer almaktadır.

Tablo 3.9. Kestirim/Eğitim Seti İçin Sınıflandırma Matrisi (t-4 Dönemi)

DISKRİMİNANT MODELİ			
		Gerçek Grup	
		<u>Başarısız İşletmeler</u>	<u>Başarılı İşletmeler</u>
Tahmin Edilen Grup	<u>Başarısız İşletmeler</u>	18 % 45	10 % 22,2
	<u>Başarılı İşletmeler</u>	22 % 55	35 % 77,8
Toplam		40	45
Toplam Sınıflandırma Doğruluğu = $(18+35)/85 = \% 62,4$			
LOJİSTİK REGRESYON MODELİ			
		Gerçek Grup	
		<u>Başarısız İşletmeler</u>	<u>Başarılı İşletmeler</u>
Tahmin Edilen Grup	<u>Başarısız İşletmeler</u>	21 % 52,5	9 % 20
	<u>Başarılı İşletmeler</u>	19 % 47,5	36 % 80
Toplam		40	45
Toplam Sınıflandırma Doğruluğu = $(21+36)/85 = \% 67,1$			
YAPAY SİNİR AĞI MODELİ			
		Gerçek Grup	
		<u>Başarısız İşletmeler</u>	<u>Başarılı İşletmeler</u>
Tahmin Edilen Grup	<u>Başarısız İşletmeler</u>	16 % 40	11 % 24,4
	<u>Başarılı İşletmeler</u>	24 % 60	34 % 75,6
Toplam		40	45
Toplam Sınıflandırma Doğruluğu = $(16+34)/85 = \% 58,8$			

Dört yıl önceden diskriminant modeli başarısız işletmeleri % 45; başarılı işletmeleri ise % 77,8 doğrulukla tahmin etmiştir. Modelin toplam sınıflandırma doğruluğu ise % 62,4 olarak hesaplanmıştır. Özellikle başarısız işletmelerin düşük oranda doğrulukla tahmin edilmesi dikkate değerdir.

Dört yıl öncesinden % 67,1 toplam sınıflandırma doğruluğuna sahip olan lojistik regresyon modeli, başarısız işletmeleri % 52,5; başarılı işletmeleri ise % 80 oranında doğru olarak sınıflandırmıştır. Dört yıl gibi uzun bir süre öncesinden, her iki grubu da % 50'nin üzerinde doğrulukla tahmin etmesi, modelin şansa dayalı sınıflandırmadan daha iyi olduğunu göstermektedir.

Yapay sinir ağı modeli, eğitim seti üzerindeki başarısız işletmelerin % 40'ının, başarılı işletmelerinse % 75,6'sının durumunu dört yıl öncesinden doğru olarak tahmin etmiştir. Yapay sinir ağının toplam sınıflandırma doğruluğu ise % 58,8 olarak gerçekleşmiştir. Toplam sınıflandırma doğruluğu, dört yıl öncesi için şansa dayalı sınıflandırma yapmaktan daha iyi görünse de, 1. tip hata oranının % 60 olması modelin dört yıl önceden tahmin yapmada kullanılmaması gerektiğine işaret etmektedir.

Başarısızlıktan dört yıl öncesi için en iyi performansa sahip model, lojistik regresyon modelidir. Diskriminant modeli ve yapay sinir ağı özellikle başarısız işletmeleri % 50'nin altında bir oranla doğru tahmin ettiği için, bu modellerin kullanılması karar vericiler için fayda sağlamayacaktır.

Diskriminant modeli, lojistik regresyon modeli ve yapay sinir ağının kontrol/test seti üzerindeki performansları Tablo 3.10.'da görülmektedir.

Tablo 3.10. Kontrol/Test Seti İçin Sınıflandırma Matrisi (t-4 Dönemi)

DİSKRİMİNANT MODELİ			
		Gerçek Grup	
		<u>Başarısız İşletmeler</u>	<u>Başarılı İşletmeler</u>
Tahmin Edilen Grup	<u>Başarısız İşletmeler</u>	9 % 60	4 % 26,7
	<u>Başarılı İşletmeler</u>	6 % 40	11 % 73,3
Toplam		15	15
Toplam Sınıflandırma Doğruluğu = $(9+11)/30 = \% 66,7$			

Tablo 3.10. Devamı

LOJİSTİK REGRESYON MODELİ			
		Gerçek Grup	
		<u>Başarısız İşletmeler</u>	<u>Başarılı İşletmeler</u>
Tahmin Edilen Grup	<u>Başarısız İşletmeler</u>	8 % 53,3	3 % 20
	<u>Başarılı İşletmeler</u>	7 % 46,4	12 % 80
Toplam		15	15
Toplam Sınıflandırma Doğruluğu = $(8+12)/30 = \% 66,7$			
YAPAY SİNİR AĞI MODELİ			
		Gerçek Grup	
		<u>Başarısız İşletmeler</u>	<u>Başarılı İşletmeler</u>
Tahmin Edilen Grup	<u>Başarısız İşletmeler</u>	9 % 60	3 % 20
	<u>Başarılı İşletmeler</u>	6 % 40	12 % 80
Toplam		15	15
Toplam Sınıflandırma Doğruluğu = $(9+12)/30 = \% 70$			

Diskriminant modeli, başarısız işletmeleri % 60; başarılı işletmeleri ise % 73,3 doğrulukla tahmin etmiştir. Diskriminant modelinin toplam sınıflandırma doğruluğu ise % 66,7 olmuştur. Söz konusu oranlar, dört yıl önceden tahmin için oldukça iyi sonuçlar olarak değerlendirilebilir.

Lojistik regresyon modeli, test setindeki 15 başarısız işletmenin 8'ini (% 53,3); 15 başarılı işletmenin de 12'sini (% 80) doğru olarak sınıflandırmıştır. Modelin toplam sınıflandırma doğruluğu ise % 66,7'dir.

Yapay sinir ağı, başarısız işletmeleri % 60; başarılı işletmeleri ise % 80 doğrulukla sınıflandırmıştır. Yapay sinir ağı modelinin toplam sınıflandırma doğruluğu da 4 yıl öncesi için oldukça iyi sayılabilecek bir seviyede % 70 olarak gerçekleşmiştir.

Başarısızlıktan dört yıl öncesinde, kontrol/test seti üzerinde en iyi performansı gösteren model yapay sinir ağı olmuştur. Diskriminant modeli ile lojistik regresyon modelinin toplam sınıflandırma doğrulukları aynı olmasına rağmen, diskriminant modelinde 1. tip hata oranı daha azdır.

3.6.2.5. Başarısızlıktan Beş Yıl Öncesi İçin Tahmin Modellerinin Performansları

Tablo 3.11.'de, modellerin beş yıl öncesinden kestirim/eğitim seti üzerindeki işletmelerin durumunu tahmin etmeye yönelik performansları yer almaktadır.

Tablo 3.11. Kestirim/Eğitim Seti İçin Sınıflandırma Matrisi (t-5 Dönemi)

DİSKRİMİNANT MODELİ			
		Gerçek Grup	
		<u>Başarısız İşletmeler</u>	<u>Başarılı İşletmeler</u>
Tahmin Edilen Grup	<u>Başarısız İşletmeler</u>	15 % 42,9	10 % 22,7
	<u>Başarılı İşletmeler</u>	20 % 57,1	34 % 77,3
Toplam		35	44
Toplam Sınıflandırma Doğruluğu = $(15+34)/79 = \% 62$			
LOJİSTİK REGRESYON MODELİ			
		Gerçek Grup	
		<u>Başarısız İşletmeler</u>	<u>Başarılı İşletmeler</u>
Tahmin Edilen Grup	<u>Başarısız İşletmeler</u>	13 % 37,1	9 % 20,5
	<u>Başarılı İşletmeler</u>	22 % 62,9	35 % 79,5
Toplam		35	44
Toplam Sınıflandırma Doğruluğu = $(13+35)/79 = \% 60,8$			
YAPAY SİNİR AĞI MODELİ			
		Gerçek Grup	
		<u>Başarısız İşletmeler</u>	<u>Başarılı İşletmeler</u>
Tahmin Edilen Grup	<u>Başarısız İşletmeler</u>	12 % 34,3	8 % 18,2
	<u>Başarılı İşletmeler</u>	23 % 65,7	36 % 81,8
Toplam		35	44
Toplam Sınıflandırma Doğruluğu = $(12+36)/79 = \% 60,8$			

Başarısızlıktan beş yıl öncesinde, işletmelerin durumunu diskriminant modeli % 62; lojistik regresyon modeli % 60,8 ve yapay sinir ağı % 60,8 doğrulukla tahmin etmiştir. Ancak, her üç modelin de başarısız işletmeleri doğru olarak tahmin etme gücü son

derece düşük çıkmıştır. Dolayısıyla modellerin beş yıl öncesi için bir tahmin değeri olmadığı söylenebilir.

Beş yıl öncesi için her üç modelin kontrol/test seti üzerindeki performansları da aşağıda Tablo 3.12.'dedir.

Tablo 3.12. Kontrol/Test Seti İçin Sınıflandırma Matrisi (t-5 Dönemi)

DİSKRİMİNANT MODELİ			
		Gerçek Grup	
		Başarısız İşletmeler	Başarılı İşletmeler
Tahmin Edilen Grup	Başarısız İşletmeler	11 % 73,3	4 % 26,7
	Başarılı İşletmeler	4 % 26,7	11 % 73,3
Toplam		15	15
Toplam Sınıflandırma Doğruluğu = $(11+11)/30 = \% 73,3$			
LOJİSTİK REGRESYON MODELİ			
		Gerçek Grup	
		Başarısız İşletmeler	Başarılı İşletmeler
Tahmin Edilen Grup	Başarısız İşletmeler	10 % 66,7	4 % 26,7
	Başarılı İşletmeler	5 % 33,3	11 % 73,3
Toplam		15	15
Toplam Sınıflandırma Doğruluğu = $(10+11)/30 = \% 70$			
YAPAY SİNİR AĞI MODELİ			
		Gerçek Grup	
		Başarısız İşletmeler	Başarılı İşletmeler
Tahmin Edilen Grup	Başarısız İşletmeler	11 % 73,3	5 % 33,3
	Başarılı İşletmeler	4 % 26,7	10 % 66,7
Toplam		15	15
Toplam Sınıflandırma Doğruluğu = $(11+10)/30 = \% 70$			

Diskriminant analizi beş yıl önceden kontrol setindeki başarısız ve başarılı işletmeleri aynı oranda doğru tahmin ederek, % 73,3 toplam sınıflandırma doğruluğuna sahip olmuştur.

Lojistik regresyon modeli ise başarısız işletmeleri % 66,7; başarılı işletmeleri ise % 73,3 oranında doğru tahmin ederek, % 70 toplam sınıflandırma doğruluğu elde etmiştir.

Yapay sinir ağı, test setindeki 15 başarısız işletmenin 11'ini (% 73,3); 15 başarılı işletmeninse 10'unu (% 66,7) doğru olarak tahmin etmeyi başarmıştır. Modelin toplam sınıflandırma doğruluğu % 70'tir.

Kontrol/test seti üzerinde her üç modelin de performansı birbirine yakın ve beş yıl önceden tahmin için iyi sayılabilecek düzeydedir. Ancak, modellerin kestirim/eğitim seti üzerindeki, özellikle başarısız işletmeleri doğru olarak tahmin etmedeki kötü performansı, modellerin başarısızlıktan beş yıl öncesi için kullanımını şüpheli hale getirmektedir.

3.6.2.6. Tüm Yıllar İçin Tahmin Modellerinin Performansları

Diskriminant modeli, lojistik regresyon modeli ve yapay sinir ağının başarısızlıktan beş yıl öncesine kadar doğru sınıflandırma oranları, toplu şekilde Tablo 3.13.'de yer almaktadır.

Tablo 3.13. Her Üç Modelin Tüm Dönemlere İlişkin Performans Ölçüleri

Dönem	DİSKRİMİNANT MODELİ			LOJİSTİK REGRESYON			YAPAY SİNİR AĞI		
	Duyarlılık	Özgüllük	Doğruluk	Duyarlılık	Özgüllük	Doğruluk	Duyarlılık	Özgüllük	Doğruluk
KESTİRİM/EĞİTİM SETİ									
t-1	% 80	% 82,2	% 81,1	% 77,8	% 84,4	% 81,1	% 95,6	% 97,8	% 96,7
t-2	% 55,6	% 62,2	% 58,9	% 60	% 68,9	% 64,4	% 71,1	% 73,3	% 72,2
t-3	% 48,8	% 73,3	% 61,4	% 51,2	% 75,6	% 63,6	% 53,5	% 55,6	% 54,5
t-4	% 45	% 77,8	% 62,4	% 52,5	% 80	% 67,1	% 40	% 75,6	% 58,8
t-5	% 42,9	% 77,3	% 62	% 37,1	% 79,5	% 60,8	% 34,3	% 81,8	% 60,8
TEST/KONTROL SETİ									
t-1	% 73,3	% 80	% 76,7	% 73,3	% 80	% 76,7	% 93,3	% 86,7	% 90
t-2	% 66,7	% 66,7	% 66,7	% 80	% 66,7	% 73,3	% 86,7	% 86,7	% 86,7
t-3	% 53,3	% 73,3	% 63,3	% 53,3	% 80	% 66,7	% 66,7	% 80	% 73,3
t-4	% 60	% 73,3	% 66,7	% 53,3	% 80	% 66,7	% 60	% 80	% 70
t-5	% 73,3	% 73,3	% 73,3	% 66,7	% 73,3	% 70	% 73,3	% 66,7	% 70

Tablo 3.13.'de kestirim/eğitim seti ve kontrol/test seti üzerinde, her dönem en iyi toplam sınıflandırma doğruluğuna sahip değer altı çizilerek gösterilmiştir. Kestirim/Eğitim seti üzerinde başarısızlıktan önceki birinci ve ikinci yılda en iyi

performansı gösteren model yapay sinir ağı modelidir. Başarısızlıktan önceki üçüncü ve dördüncü yılda ise en iyi performansa sahip model lojistik regresyon modelidir. Beş yıl önceden işletmenin durumunu tahmin etmede diskriminant modeli biraz daha iyi toplam sınıflandırma doğruluğuna sahip olmakla birlikte, üç modelin genel performansı birbirine yakın seviyelerdedir. Ancak, üç modelin de başarısız işletmeleri yanlış şekilde başarılı olarak sınıflandırma (1. tip hata) oranları yüksek olduğundan, karar verici için faydalı birer araç olmaktan çıktıkları söylenebilir.

Kontrol/test seti üzerinde, başarısızlıktan önceki ilk dört yıl en iyi performansı yapay sinir ağı göstermiştir. Beş yıl öncesinde ise üç modelin de performansı birbirine yakın olmakla birlikte diskriminant analizinin performansı biraz daha iyidir. Ancak, daha önce de belirtildiği gibi kestirim/egitim seti üzerindeki farklı performansdan dolayı, modellerin beş yıl öncesi için kontrol/test seti üzerindeki tahmin gücü ihtiyatla değerlendirilmelidir.

İşletme ile ilgili çeşitli kararları vermede ve gerekli önlemleri alabilmede iki yıl gibi bir sürenin oldukça uzun olduğu dikkate alınır, yüksek doğruluk performansı ile yapay sinir ağlarının çok yararlı bir yöntem olduğu açıktır. Ancak, bu performans ölçülerine göre, başarısızlıktan dört yıl öncesine kadar gerek kestirim/egitim seti üzerinde, gerekse kontrol/test seti üzerinde en istikrarlı sonuçları lojistik regresyon modelinin elde ettiği de gözardı edilmemelidir. Yani tahmin için iki yıldan daha fazla süreye ihtiyaç duyulan, uzun vadeli kararlarda lojistik regresyon modelinin kullanılması fayda sağlayabilecektir.

3.7. ROC EĞRİLERİ YARDIMIYLA TAHMİN MODELLERİNİN PERFORMANSLARININ DEĞERLENDİRMESİ

3.7.1. ROC Eğrileri (Receiver Operating Characteristic Curves)

Doğru sınıflandırma oranı (toplam sınıflandırma doğruluğu) en yaygın olarak kullanılan performans ölçüsü olmasına rağmen, finansal başarısızlık tahmini gibi iki gruplu sınıflandırma problemleri için yanıltıcı olabilmektedir. Çünkü, doğru sınıflandırma oranı 1. tip hata ile 2. tip hatayı birleştirmektedir. Yani, doğru sınıflandırma oranı, eğer birbirine eşit değilse 1. tip hata ve 2 tip hata arasındaki nisbi yanlış sınıflandırma

maliyetlerini ihmal etmektedir. Üstelik, doğruluk, duyarlılık ve özgüllük gibi performans ölçüleri sadece önceden belirlenmiş bir kopuş değeri için geçerlidir¹⁶⁷.

Tahmin modellerinin performanslarının değerlendirilmesi ve kıyaslanması için bu sınırlamaların üstesinden gelen en değerli yöntemlerden biri ROC eğrisidir. ROC eğrisi, önsel olasılıklardan ve kopuş değerlerinden bağımsız bir performans ölçüsüdür.

ROC eğrileri, farklı kopuş değerleri için bulunan farklı duyarlılık-özgüllük karakterlerine bağlı olarak ara seçenekler belirlenerek oluşturulmaktadır.

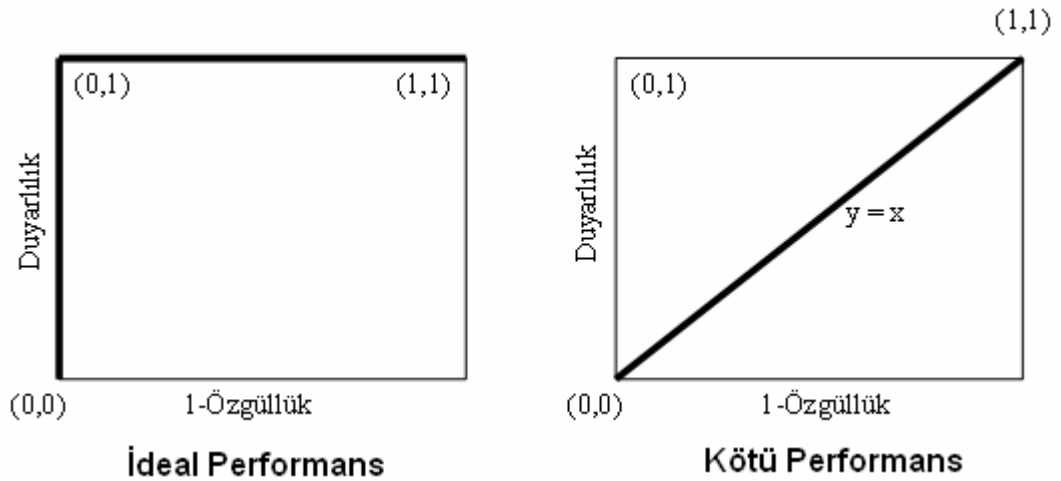
ROC eğrisi yöntemi¹⁶⁸;

- Modelin sınıflandırma gücünün belirlenmesine,
- Çeşitli modellerin etkinliklerinin kıyaslanmasına,
- En uygun kopuş değerinin belirlenmesine,
- Sonuçların kalitesinin izlenmesine olanak sağlamaktadır.

ROC eğrisinin oluşturulacağı koordinat sisteminin ordinatında, testin gerçek pozitif oranı (duyarlılık), apsisinde ise yanlış pozitif oranı (1-özgüllük) yer alır. Model ne kadar iyi ise eğri o kadar yukarıya (yüksek duyarlılık bölgesi) ve sola (düşük yanlış pozitif oranı bölgesi) doğru kayar. Yanlış değerlere sahip olmayan ideal bir modelde, ROC eğrisi (0,0) - (0,1) - (1,1) noktalarını birleştirmektedir. Buna karşın ROC çizimi $y=x$ fonksiyonuna yaklaştıkça başarısız bir model ortaya çıkar. Çünkü bu modelde yanlış değerlerin oranı artmaktadır. Bu fonksiyonun altındaki ROC eğrisine sahip bir model başarısızdır. Bu durum Şekil 3.2. de görülmektedir.

¹⁶⁷ Argryou, a.g.e., pp.44-45.

¹⁶⁸ Dirican, a.g.e., s.29.




Şekil 3.2. İdeal ve Kötü Performans Göstergesi Olan ROC Eğrileri

ROC eğrisi altında kalan alan, aynı örnek üzerinde geliştirilmiş modellerin performansını karşılaştırmada sağlam bir performans ölçüsüdür. Bir modelin ROC eğrisi altında kalan alanı, modelin doğru tahmin olasılığını göstermektedir¹⁶⁹. Bir tahmin testi için ROC altında kalan alan etkinlik düzeyine bağlı olarak 0.50 ile 1.00 arasında değerler alabilecektir. Bu alan ne kadar büyükse, tahmin testi o denli ayırım yeteneğine sahip olacaktır. Bu alan 0.975 ve daha üzerinde ise mükemmel sayılmaktadır.

3.7.2. Başarısızlıktan Bir Yıl Öncesi İçin ROC Eğrileri Kullanılarak Modellerin Karşılaştırılması

Başarısızlıktan bir yıl öncesi için diskriminant analizi (DA), lojistik regresyon analizi (LR) ve yapay sinir ağı (YSA) modellerine ilişkin kestirim/egitim seti için ROC eğrileri Şekil 3.3.'de, ROC eğrisi altında kalan alanlar ise Tablo 3.14'de görülmektedir.

¹⁶⁹ Argyrou, a.g.e, p.47.



Şekil 3.3. Kestirim/Eğitim Seti ROC Eğrileri (t-1 Dönemi)

Tablo 3.14. Kestirim/Eğitim Seti ROC Eğrileri Altında Kalan Alanlar (t-1 Dönemi)

MODEL	ROC Altında Kalan Alan	Standart Sapma	% 95 Güven Aralığı	P Anlam Düzeyi (H_0 : Alan = 0,50)
DA	0,904	0,033	0,823-0,956	0,0001
LR	0,907	0,033	0,827-0,958	0,0001
YSA	0,995	0,007	0,950-0,996	0,0001


Her üç modelin de ROC eğrileri altında kalan alanları oldukça yüksektir. Bununla birlikte, yapay sinir ağının eğri altında kalan alanının 0,995 olması, yapay sinir ağının başarısızlıktan bir yıl öncesinde mükemmel yakın tahminde bulunduğunu göstermektedir. P değerlerine bakıldığında, tüm modellerin tahmin yeteneğinin istatistiksel olarak anlamlı olduğu anlaşılmaktadır. Aşağıda Tablo 3.15.'de modellerin ROC eğrileri altında kalan alanlarının ikili karşılaştırma sonuçları sunulmuştur.

Tablo 3.15. Kestirim/Eđitim Seti ROC Eđrileri Altında Kalan Alanlar İin İkili Karşılařtırma Sonuları (t-1 Dönemi)

MODELLER	ROC Altında Kalan Alanlar Arası Fark	Standart Sapma	% 95 Güven Aralığı	P Anlam Düzeyi
DA-LR	0,003	0,014	-0,025-0,031	0,836
DA-YSA	0,091	0,028	0,036-0,147	0,0001
LR-YSA	0,088	0,028	0,033-0,144	0,0002

Tablo 3.15’de görüldüğü gibi, yapay sinir ağı modelinin ROC eğrisi altında kalan alanı hem diskriminant modelininkinden hem de lojistik regresyon modelininkinden istatistiksel olarak anlamlı şekilde farklıdır. Diskriminant modeliyle lojistik regresyon modelinin performansı arasında ise anlamlı bir fark bulunmamaktadır.

Kontrol/test seti üzerindeki performanslar için ROC eğrileri Şekil 3.4.’de, ROC eğrisi altında kalan alanlar ise Tablo 3.16’da görülmektedir.



Şekil 3.4. Kontrol/Test Seti ROC Eğrileri (t-1 Dönemi)

Tablo 3.16. Kontrol/Test Seti ROC Eğrileri Altında Kalan Alanlar (t-1 Dönemi)

MODEL	ROC Altında Kalan Alan	Standart Sapma	% 95 Güven Aralığı	P Anlam Düzeyi (H ₀ : Alan = 0,50)
DA	0,871	0,067	0,698-0,964	0,0001
LR	0,840	0,075	0,661-0,947	0,0001
YSA	0,911	0,056	0,749-0,982	0,0001

Her üç modelin performansı da istatistiksel olarak anlamlıdır. ROC eğrileri altında kalan alanlara bakıldığında, en büyük alana sahip olan model yapay sinir ağıdır. Yapay sinir ağının ROC altında kalan alanı 0,911'dir. Dolayısıyla, kontrol/test seti için en iyi performansa sahip model de yapay sinir ağı olarak görülmektedir. Model performanslarının ikili karşılaştırma sonuçları Tablo 3.17.'de yer almaktadır.


Tablo 3.17. Kontrol/Test Seti ROC Eğrileri Altında Kalan Alanlar İçin İkili Karşılaştırma Sonuçları (t-1 Dönemi)

MODELLER	ROC Altında Kalan Alanlar Arası Fark	Standart Sapma	% 95 Güven Aralığı	Anlam Düzeyi
DA-LR	0,031	0,035	-0,038-0,100	P = 0,377
DA-YSA	0,040	0,058	-0,075-0,155	P = 0,494
LR-YSA	0,071	0,070	-0,066-0,208	P = 0,308

Modellerin ROC eğrisi altında kalan alanlarının ikili karşılaştırmaları sonucunda, % 5 anlam düzeyinde modeller arasında istatistiksel olarak anlamlı bir fark bulunmadığı görülmüştür.

3.7.3. Başarısızlıktan İki Yıl Öncesi İçin ROC Eğrileri Kullanılarak Modellerin Karşılaştırılması

Başarısızlıktan iki yıl öncesi için modellere ait ROC eğrileri Şekil 3.5.'de, ROC eğrisi altında kalan alanlar ise Tablo 3.18.'de yer almaktadır.



Şekil 3.5. Kestirim/Eğitim Seti ROC Eğrileri (t-2 Dönemi)

Tablo 3.18. Kestirim/Eğitim Seti ROC Eğrileri Altında Kalan Alanlar (t-2 Dönemi)

MODEL	ROC Altında Kalan Alan	Standart Sapma	% 95 Güven Aralığı	P Anlam Düzeyi (H ₀ : Alan = 0,50)
DA	0,682	0,056	0,576-0,777	0,0012
LR	0,695	0,055	0,589-0,788	0,0004
YSA	0,762	0,050	0,661-0,846	0,0001

Başarısızlıktan iki yıl öncesinde, kestirim/eğitim seti için en büyük ROC eğrisi altında kalan alana sahip olan model yapay sinir ağıdır. ROC eğrilerini gösteren grafikten de, yapay sinir ağının ROC eğrisinin sola ve üste daha yakın olduğu görülmektedir. Diskriminant modeli ile lojistik regresyon modelinin ROC eğrisi altında kalan alanları ise birbirine oldukça yakındır. Yani, her iki modelin başarısız ve başarılı işletmeleri ayırım gücünün birbirine çok yakın olduğu söylenebilir. Her üç model de istatistiksel olarak anlamlı bulunmuştur.


Başarısızlıktan iki yıl öncesinde, ROC eğrisi altında kalan alanlara ilişkin ikili karşılaştırma sonuçları aşağıda Tablo 3.19.'da görülmektedir.

Tablo 3.19. Kestirim/Eđitim Seti ROC Eđrileri Altında Kalan Alanlar İin İkili Karşılařtırma Sonuları (t-2 Dnemi)

MODELLER	ROC Altında Kalan Alanlar Arası Fark	Standart Sapma	% 95 Gven Aralıđı	Anlam Dzeyi
DA-LR	0,013	0,020	-0,027-0,052	P = 0,529
DA-YSA	0,080	0,039	0,004-0,156	P = 0,039
LR-YSA	0,067	0,039	-0,010-0,144	P = 0,086

Modeller arası karşılařtırma sonuları, % 5 anlam dzeyinde sadece diskriminant modeliyle yapay sinir ađı arasında anlamlı bir fark bulunduđunu gstermektedir.

Her  modelin, bařarısızlıktan iki yıl ncesi iin kontrol/test seti zerindeki performanslarını gsteren ROC eđrileri Őekil 3.6.'da, ROC eđrisi altında kalan alanlar ise Tablo 3.20.'de sunulmuřtur.



Őekil 3.6. Kontrol/Test Seti ROC Eđrileri (t-2 Dnemi)

Tablo 3.20. Kontrol/Test Seti ROC Eğrileri Altında Kalan Alanlar (t-2 Dönemi)

MODEL	ROC Altında Kalan Alan	Standart Sapma	% 95 Güven Aralığı	P Anlam Düzeyi (H ₀ : Alan = 0,50)
DA	0,813	0,080	0,629-0,931	0,0001
LR	0,787	0,085	0,599-0,914	0,0007
YSA	0,916	0,055	0,755-0,984	0,0001

Tüm modellerin ROC eğrisi altında kalan alanları, kötü performansı temsil eden 0,50 alanından istatistiksel olarak anlamlı derecede farklıdır. Gerek grafikten, gerekse ROC eğrisi altında kalan alanlardan anlaşılacağı gibi, kontrol/test seti üzerinde de en iyi performans gösteren model yapay sinir ağıdır. Yapay sinir ağının ROC eğrisi altında kalan alanı 0,916'dır. Yapay sinir ağını, 0,813 ROC eğrisi altında kalan alana sahip diskriminant modeli izlemektedir. Modellerin ROC eğrisi altında kalan alanları arasında anlamlı bir fark bulunup bulunmadığını gösteren ikili karşılaştırmalar Tablo 3.21.'de yer almaktadır.


Tablo 3.21. Kontrol/Test Seti ROC Eğrileri Altında Kalan Alanlar İçin İkili Karşılaştırma Sonuçları (t-2 Dönemi)

MODELLER	ROC Altında Kalan Alanlar Arası Fark	Standart Sapma	% 95 Güven Aralığı	Anlam Düzeyi
DA-LR	0,027	0,031	-0,033-0,087	P = 0,383
DA-YSA	0,102	0,073	-0,040-0,244	P = 0,159
LR-YSA	0,129	0,075	-0,018-0,276	P = 0,085

Başarısızlıktan iki yıl öncesinde, kontrol/test üzerindeki modellerin performanslarını gösteren ROC eğrileri altında kalan alanlar karşılaştırıldığında, aralarında % 5 anlam seviyesinde önemli sayılabilecek bir fark bulunmadığı görülmektedir.

3.7.4. Başarısızlıktan Üç Yıl Öncesi İçin ROC Eğrileri Kullanılarak Modellerin Karşılaştırılması

Başarısızlıktan üç yıl öncesi için, modellerin kestirim/eğitim seti üzerindeki performanslarını gösteren ROC eğrileri Şekil 3.7.'de, eğri altında kalan alanlar ise Tablo 3.22.'de görülmektedir.



Şekil 3.7. Kestirim/Eğitim Seti ROC Eğrileri (t-3 Dönemi)

Tablo 3.22. Kestirim/Eğitim Seti ROC Eğrileri Altında Kalan Alanlar (t-3 Dönemi)

MODEL	ROC Altında Kalan Alan	Standart Sapma	% 95 Güven Aralığı	P Anlam Düzeyi (H ₀ : Alan = 0,50)
DA	0,598	0,061	0,488-0,701	0,1058
LR	0,589	0,061	0,479-0,692	0,1439
YSA	0,546	0,062	0,437-0,653	0,4523

Grafikten görüldüğü üzere, başarısızlıktan üç yıl öncesi için her üç modelin performansı da birbirine oldukça yakın düzeydedir. Her üç modelin de ROC eğrisi altında kalan alanları 0,50 den büyük olmakla birlikte, bu fark % 5 anlam düzeyinde önemli bulunmamıştır. Dolayısıyla, modellerin başarısızlıktan üç yıl öncesi iyi sayılmayacak


bir performans gösterdikleri söylenebilir. Modeller arası ikili karşılaştırma sonuçları Tablo 3.23’de sunulmuştur.

Tablo 3.23. Kestirim/Eğitim Seti ROC Eğrileri Altında Kalan Alanlar İçin İkili Karşılaştırma Sonuçları (t-3 Dönemi)

MODELLER	ROC Altında Kalan Alanlar Arası Fark	Standart Sapma	% 95 Güven Aralığı	Anlam Düzeyi
DA-LR	0,009	0,030	-0,049-0,067	P = 0,754
DA-YSA	0,052	0,047	-0,040-0,143	P = 0,268
LR-YSA	0,042	0,047	-0,049-0,134	P = 0,363

İkili karşılaştırma sonuçları, başarısızlıktan üç yıl öncesi için modellerin ROC eğrisi altında kalan alanlarının, % 5 anlam düzeyinde birbirinden önemli sayılabilecek derecede farklı olmadığını göstermektedir.

Modellerin kontrol/test seti üzerindeki tahminlerinden elde edilmiş ROC eğrileri Şekil 3.8.’de, eğri altında kalan alanları ise Tablo 3.24.’de görülmektedir.



Şekil 3.8. Kontrol/Test Seti ROC Eğrileri (t-3 Dönemi)

Tablo 3.24. Kontrol/Test Seti ROC Eğrileri Altında Kalan Alanlar (t-3 Dönemi)

MODEL	ROC Altında Kalan Alan	Standart Sapma	% 95 Güven Aralığı	P Anlam Düzeyi (H ₀ : Alan = 0,50)
DA	0,791	0,084	0,604-0,917	0,0005
LR	0,729	0,093	0,536-0,874	0,0140
YSA	0,831	0,076	0,650-0,942	0,0001

ROC eğrisi altında kalan alanlar incelendiğinde, başarısızlıktan üç yıl önce kontrol/test setinde yer alan işletmelerin durumlarını tahminde en başarılı modelin, yapay sinir ağı olduğu görülmektedir. Yapay sinir ağından sonra en iyi performansa sahip model, 0,791 ROC eğrisi altında kalan alana sahip diskriminant analizidir. Her üç model de % 5 anlam düzeyinde, kötü performansı gösteren 0,50 alanından anlamlı derecede farklı bulunmuştur. Modeller arası ikili karşılaştırma sonuçları, aşağıda Tablo 3.25.'de yer almaktadır.


Tablo 3.25. Kontrol/Test Seti ROC Eğrileri Altında Kalan Alanlar İçin İkili Karşılaştırma Sonuçları (t-3 Dönemi)

MODELLER	ROC Altında Kalan Alanlar Arası Fark	Standart Sapma	% 95 Güven Aralığı	Anlam Düzeyi
DA-LR	0,062	0,030	0,003-0,122	P = 0,041
DA-YSA	0,040	0,070	-0,098-0,178	P = 0,570
LR-YSA	0,102	0,082	-0,058-0,262	P = 0,211

İkili karşılaştırma sonuçları, sadece diskriminant modeliyle lojistik regresyon arasındaki farkın % 5 anlam düzeyinde istatistiksel olarak anlamlı olduğunu göstermektedir.

3.7.5. Başarısızlıktan Dört Yıl Öncesi İçin ROC Eğrileri Kullanılarak Modellerin Karşılaştırılması

Modellerin başarısızlıktan dört yıl öncesi için kestirim/eğitim seti üzerindeki performanslarını gösteren ROC eğrileri Şekil 3.9.'da ve ROC eğrisi altında kalan alanlar ise Tablo 3.26.'da sunulmuştur.



Şekil 3.9. Kestirim/Eğitim Seti ROC Eğrileri (t-4 Dönemi)

Tablo 3.26. Kestirim/Eğitim Seti ROC Eğrileri Altında Kalan Alanlar (t-4 Dönemi)

MODEL	ROC Altında Kalan Alan	Standart Sapma	% 95 Güven Aralığı	P Anlam Düzeyi (H ₀ : Alan = 0,50)
DA	0,696	0,058	0,586-0,791	0,0007
LR	0,680	0,058	0,570-0,777	0,0018
YSA	0,598	0,061	0,486-0,702	0,1123

Başarısızlıktan 4 yıl öncesi için en iyi tahmin gücüne sahip model, ROC eğrisi altında kalan alanı en büyük olan diskriminant analizidir. Diskriminant modeli ve lojistik regresyon modeli, ROC eğrilerinin değerlendirilmesinde kullanılan 0,50 referans değerinden istatistiksel olarak anlamlı şekilde farklı ROC eğrisi altında kalan alanlara sahiptir. Şekil 3.9.'dan açık şekilde görüleceği gibi her iki modelin performansı birbirine oldukça yakındır. Buna karşılık, yapay sinir ağının eğri altında kalan alanının % 5 anlam düzeyinde 0,50 den anlamlı derecede farklı olmadığı anlaşılmıştır. Dolayısıyla, yapay sinir ağının başarısızlıktan dört yıl öncesinde kötü performans gösterdiğini söyleyebiliriz.


Modellere ilişkin ikili sınıflandırma sonuçları Tablo 3.27.'de yer almaktadır.

Tablo 3.27. Kestirim/Eđitim Seti ROC Eđrileri Altında Kalan Alanlar İin İkili Karşılařtırma Sonuları (t-4 Dönemi)

MODELLER	ROC Altında Kalan Alanlar Arası Fark	Standart Sapma	% 95 Güven Aralığı	Anlam Düzeyi
DA-LR	0,016	0,017	-0,018-0,050	P = 0,370
DA-YSA	0,098	0,058	-0,016-0,212	P = 0,092
LR-YSA	0,083	0,057	-0,029-0,194	P = 0,147

Başarısızlıktan dört yıl önce, modellerin işletmelerin durumunu tahmin güçleri arasında % 5 anlam düzeyinde önemli bir fark bulunamamıştır.

Başarısızlıktan dört yıl öncesi için modellerin kontrol/test seti üzerindeki ROC eđrileri Şekil 3.10.'da ve eđri altında kalan alanlar ise Tablo 3.28.'de yer almaktadır.



Şekil 3.10. Kontrol/Test Seti ROC Eđrileri (t-4 Dönemi)

Tablo 3.28. Kontrol/Test Seti ROC Eğrileri Altında Kalan Alanlar (t-4 Dönemi)

MODEL	ROC Altında Kalan Alan	Standart Sapma	% 95 Güven Aralığı	P Anlam Düzeyi (H ₀ : Alan = 0,50)
DA	0,724	0,094	0,532-0,870	0,0167
LR	0,698	0,097	0,504-0,851	0,0411
YSA	0,760	0,089	0,570-0,896	0,0035

Dört yıl önceden işletmenin durumunun tahmin edilmesinde, kontrol/test seti üzerinde en iyi performansa sahip modelin yapay sinir ağı olduğu görülmektedir. Çünkü, 0,760 olan ROC eğrisi altında kalan alanı, diğer modellerin alanlarından daha büyüktür. Her üç model de kötü performansı temsil eden 0,50 alanından, % 5 anlam düzeyinde önemli derecede daha farklı alanlara sahiptir. Tablo 3.29.'da ikili karşılaştırma sonuçları yer almaktadır.

Tablo 3.29. Kontrol/Test Seti ROC Eğrileri Altında Kalan Alanlar İçin İkili Karşılaştırma Sonuçları (t-4 Dönemi)


MODELLER	ROC Altında Kalan Alanlar Arası Fark	Standart Sapma	% 95 Güven Aralığı	Anlam Düzeyi
DA-LR	0,027	0,035	-0,042-0,095	P = 0,446
DA-YSA	0,036	0,064	-0,090-0,161	P = 0,579
LR-YSA	0,062	0,074	-0,083-0,208	P = 0,402

İkili karşılaştırma sonuçları, finansal başarısızlıktan dört yıl öncesinde, modellerin kontrol/test seti üzerindeki performanslarını gösteren ROC eğrisi altında kalan alanları arasında % 5 anlam düzeyinde önemli sayılabilecek bir fark bulunmadığını göstermektedir.

3.7.6. Başarısızlıktan Beş Yıl Öncesi İçin ROC Eğrileri Kullanılarak Modellerin Karşılaştırılması

Diskriminant modeli, lojistik regresyon modeli ve yapay sinir ağının, beş yıl önceden kestirim/egitim setinde yer alan işletmelerin durumlarını tahmin etmedeki

performanslarını gösteren ROC eğrileri Şekil 3.11’de ve eğri altında kalan alanlar ise Tablo 3.30.’da yer almaktadır.



Şekil 3.11. Kestirim/Eğitim Seti ROC Eğrileri (t-5 Dönemi)

Tablo 3.30. Kestirim/Eğitim Seti ROC Eğrileri Altında Kalan Alanlar (t-5 Dönemi)

MODELLER	ROC Altında Kalan Alan	Standart Sapma	% 95 Güven Aralığı	P Anlam Düzeyi (H ₀ : Alan = 0,50)
DA	0,659	0,062	0,544-0,762	0,0108
LR	0,620	0,063	0,504-0,727	0,0561
YSA	0,686	0,059	0,572-0,786	0,0017


ROC eğrisi altında kalan en büyük alana sahip model, yapay sinir ağıdır. Yapay sinir ağı ve diskriminant modelinin alanları kötü performansı temsil eden 0,50 alanından % 5 anlam düzeyinde önemli derecede farklı bulunmuştur. Bu durum, beş yıl gibi uzun sayılabilecek bir süre öncesinde tahmin için bu modellerin kullanılabilceği yönünde ümit vermektedir. Modellerin eğri altında kalan alanlarının ikili karşılaştırma sonuçları aşağıda Tablo 3.31.’de sunulmuştur.

Tablo 3.31. Kestirim/Eđitim Seti ROC Eđrileri Altında Kalan Alanlar İin İkili Karşılařtırma Sonuları (t-5 Dönemi)

MODEL	ROC Altında Kalan Alanlar Arası Fark	Standart Sapma	% 95 Güven Aralığı	Anlam Düzeyi
DA-LR	0,039	0,022	-0,004-0,081	P = 0,073
DA-YSA	0,027	0,042	-0,055-0,110	P = 0,518
LR-YSA	0,066	0,043	-0,017-0,150	P = 0,121

Modellerin ROC eđrisi altında kalan alanları arasındaki farklar, % 5 anlam düzeyinde istatistiksel olarak anlamlı deđildir. Yukarıda yer alan grafikte, her üç modelin birbirine olan yakınlığından da modeller arasında önemli bir performans farkı olmadığı anlaşılmaktadır.

Kontrol/test seti üzerinde 5 yıl öncesi tahmin sonuçları için oluşturulmuş ROC eđrileri Şekil 3.12.'de ve eđri altında kalan alanlar ise Tablo 3.32.'de yer almaktadır.



Şekil 3.12. Kontrol/Test Seti ROC Eđrileri (t-5 Dönemi)

Tablo 3.32. Kontrol/Test Seti ROC Eğrileri Altında Kalan Alanlar (t-5 Dönemi)

MODEL	ROC Altında Kalan Alan	Standart Sapma	% 95 Güven Aralığı	P Anlam Düzeyi (H ₀ : Alan = 0,50)
DA	0,707	0,096	0,513-0,857	0,0311
LR	0,716	0,095	0,522-0,864	0,0230
YSA	0,698	0,097	0,504-0,851	0,0411

Başarısızlıktan beş yıl önce, kontrol/test seti üzerinde en iyi performansı lojistik regresyon modeli göstermekle birlikte, her üç modelin ROC eğrisi altında kalan alanları birbirine oldukça yakındır. Üç modelin de ROC eğrileri altında kalan alanları, kötü performansı temsil eden 0,50 alanından anlamlı derecede farklıdır. Bu da, kestirim/eğitim seti üzerinde elde edilen bulguları destekler niteliktedir. Yani beş yıl gibi uzun bir dönem önceden, işletmelerin başarılı ya da başarısız olma durumlarının tahmin edilmesinde bu yöntemler kullanılabilir. Modeller arası ikili karşılaştırma sonuçları Tablo 3.33.'de yer almaktadır.

Tablo 3.33. Kontrol/Test Seti ROC Eğrileri Altında Kalan Alanlar İçin İkili Karşılaştırma Sonuçları (t-5 Dönemi)

MODELLER	ROC Altında Kalan Alanlar Arası Fark	Standart Sapma	% 95 Güven Aralığı	Anlam Düzeyi
DA-LR	0,009	0,024	-0,039-0,057	P = 0,716
DA-YSA	0,009	0,055	-0,100-0,117	P = 0,872
LR-YSA	0,018	0,056	-0,092-0,127	P = 0,750

Gerek grafikten, gerekse ROC eğrisi altında kalan alanların büyüklüğünden açık bir şekilde görüldüğü gibi, modellerin performansları birbirine oldukça yakındır. Nitekim üç modelin de ROC eğrisi altında kalan alanları arasında, % 5 anlam düzeyinde istatistiksel olarak anlamlı bir fark bulunmadığı anlaşılmıştır.

3.7.7. Tüm Yıllar İçin ROC Eğrileri Altında Kalan Alanlar

Aşağıda, başarısızlıktan beş yıl öncesine kadar tüm yıllar için, üç modelin ROC eğrisi altında kalan alanları Tablo 3.34.'de toplu şekilde sunulmuştur.

Tablo 3.34. Her Üç Modelin Tüm Dönemlere İlişkin ROC Eğrisi Altında Kalan Alanları

		DA	LR	YSA
EĞİTİM SETİ	t-1	0,904*	0,907*	<u>0,995*</u>
	t-2	0,682*	0,695*	<u>0,762*</u>
	t-3	<u>0,598</u>	0,589	0,546
	t-4	<u>0,696*</u>	0,680*	0,598
	t-5	0,659*	0,620	<u>0,686*</u>
TEST SETİ	t-1	0,871*	0,840*	<u>0,911*</u>
	t-2	0,813*	0,887*	<u>0,916*</u>
	t-3	0,791*	0,729*	<u>0,831*</u>
	t-4	0,724*	0,698*	<u>0,760*</u>
	t-5	0,707*	<u>0,716*</u>	0,698*

* P<0,05

Başarısızlıktan önceki tüm dönemler için, ROC eğrisi altında kalan en büyük alana sahip model altı çizilerek gösterilmiştir. Kestirim/egitim seti üzerinde, başarısızlıktan önceki ilk iki yıl için, eğri altında kalan en büyük alana sahip model yapay sinir ağıdır. Başarısızlıktan üç ve dört yıl öncesinde ise diskriminant analizinin başarısız ve başarılı işletmeleri ayırma gücü diğer modellerden daha iyidir. Beş yıl öncesinde ise en iyi performans sergileyen model yine yapay sinir ağı olmuştur.

Kontrol/test seti üzerinde ise başarısızlıktan dört yıl öncesine kadar tüm yıllarda en iyi performansı gösteren model yapay sinir ağıdır. Beş yıl önceki dönem içinse her üç modelin eğri altında kalan alanları birbirine oldukça yakındır. Çok küçük bir farkla lojistik regresyon modelinin diğer modellerden daha büyük bir alana sahip olduğu görülmektedir.

Modellerin tüm yıllarda, her iki örnek seti için de 0,50 nin üzerinde ROC eğrisi altında kalan alana sahip olması, model kullanmanın şansa dayalı tahmin yapmaktan daha iyi olması anlamına gelmektedir.

Uzun vadeli bazı stratejik kararlar dışında, pek çok yönetim, yatırım ve kredi kararı için iki yılın yeterli bir süre olduğu düşünüldüğünde, sanayi işletmelerinin durumunu tahmin etmede yapay sinir ağlarının geleneksel istatistikî yöntemlerden daha faydalı bir yöntem olduğu söylenebilir. Çünkü, hem geleneksel performans ölçülerine göre hem de ROC eğrilerine göre yapay sinir ağlarının başarısızlıktan bir ve iki yıl öncesi performansı, diğer yöntemlerden çok daha iyidir.

Ayrıca, başarısızlıktan üç, dört ve beş yıl öncesinde, geleneksel performans ölçüleriyle ROC eğrileri en iyi model konusunda farklı sonuçlar vermişlerdir. Bu da, geleneksel performans ölçülerinin finansal başarısızlık tahmini gibi ikili sınıflandırma modellerini değerlendirmede yanıltıcı sonuçlar verebileceği yönündeki görüşü desteklemektedir. Gerçekte, başarısız ve başarılı işletmeleri birbirinden ayırmada yeteneği daha yüksek olmasına rağmen, bir modelin performansı önceden belirlenmiş spesifik bir kopuş değeri için düşük çıkabilmektedir. Bu nedenle, aynı örnek üzerinde geliştirilmiş modellerin performansını değerlendirmede ve karşılaştırmada, ROC eğrileri daha uygun bir performans ölçüsüdür.

SONUÇ

Bireysel ve sosyal etkilere sahip finansal başarısızlığın önceden doğru olarak tahmin edilebilmesi finans alanında önemli bir araştırma konusu olmuş ve bu konuda çok sayıda araştırma yapılmıştır. Yapılan çalışmalarda çok farklı yöntemler kullanıldığı görülmektedir. Bunlar arasında çok değişkenli istatistiki teknikler ve yapay sinir ağları finansal başarısızlık tahmini için en uygun ve en başarılı yöntemler olarak karşımıza çıkmaktadır.

Her koşul ve ortamda kullanılacak mükemmel bir tahmin yöntemi ve modelinin olmayışı, literatürde farklı veriler üzerinde farklı yöntemler kullanarak uygun model bulma arayışını devam ettirmektedir. Bu nedenle bu çalışmada, geleneksel istatistiki teknikler ve yapay sinir ağlarının Türkiye'deki sanayi şirketlerinin başarısızlıklarını tahmin edebilmedeki performansları karşılaştırılarak, en uygun yöntemin tespit edilmesi amaçlanmıştır.

Finansal başarısızlık tahmin modelleri kurmada geleneksel istatistiki teknikleri temsilen diskriminant analizi ve lojistik regresyon analizi, yapay sinir ağları içinse geri yayımlı çok katmanlı sinir ağı tercih edilmiştir. İ.M.K.B.'ye kayıtlı 90 sanayi işletmesinin 1992-2004 yılları arasındaki verilerinden, başarı ya da başarısızlıktan bir yıl öncesi verileri kullanılarak kurulan modellerin, beş yıl öncesine kadarki tahmin performansları değerlendirilmiş ve birbiriyle karşılaştırılmıştır.

Bu çalışmada finansal başarısızlık modellerinin performanslarını değerlendirmede, literatürde yaygın olarak kullanılan performans ölçülerinin yanı sıra yanıltıcı sonuçları engellemek için ROC eğrileri de kullanılmıştır.

1. tip hata (başarısız işletmelerin başarılı olarak sınıflandırılması) ile 2. tip hata (başarılı işletmelerin başarısız olarak sınıflandırılması) maliyetleri arasında fark olmadığı varsayımına dayanan geleneksel performans ölçülerine göre başarısızlıktan bir ve iki yıl

öncesi için en iyi tahmini yapay sinir ağı yapmıştır. Yapay sinir ağı kestirim/eğitim setindeki işletmeleri bir yıl öncesinden % 96,7, iki yıl öncesinden ise % 72,2 doğrulukla sınıflandırmıştır. Yapay sinir ağının kontrol/test seti üzerindeki doğru sınıflandırma oranları da bir yıl öncesi için % 90, iki yıl öncesi içinse % 86,7'dir. Toplam sınıflandırma doğruluğu ölçüsüne göre kestirim/eğitim seti üzerinde başarısızlıktan üç ve dört yıl öncesinde lojistik regresyon analizi, beş yıl öncesinde ise diskriminant analizi en iyi performansa sahip olmuştur. Kontrol/test seti üzerinde ise üç ve dört yıl önceden en iyi tahmini yapay sinir ağı yaparken, beş yıl öncesinde en iyi performans diskriminant analizine aittir. Başarısızlıktan önceki ilk iki yıl için elde edilen sonuçların oldukça iyi sayılabileceği söylenebilir. Daha geriye gidildiğinde ise tüm modellerin özellikle başarısız işletmeleri doğru tahmin etme oranları çok düşük olduğundan, toplam doğrulukları ihtiyatla karşılanmalıdır.

Yukarıdaki değerlendirmelerde kullanılan performans ölçüleri önceden belirlenmiş tek bir kopuş değerine dayanarak yapılmaktadır. Bundan dolayı, bu ölçüler kullanıldığında, bir modelin başarısız ve başarılı işletmeleri ayırım gücü esasında daha iyi olmasına rağmen, belirlenen kopuş değerindeki performansı yanıltıcı olarak düşük görülebilir. Bu nedenle bu çalışmada geliştirilen tahmin modellerinin performansları, ROC eğrileri de kullanılarak daha gerçekçi bir şekilde değerlendirilmiştir. Başarısız işletmeleri başarılı olarak yanlış sınıflandırmanın maliyetinin, diğer yanlış sınıflandırma maliyetinden çok daha fazla olduğu düşünüldüğünde, ROC eğrilerinin finansal başarısızlık tahmini için daha uygun bir performans değerlendirme tekniği olduğu aşikardır.

ROC eğrisi altında kalan alanlara göre yapılan karşılaştırmada, başarısızlıktan bir ve iki yıl öncesi her iki örnek seti üzerinde en iyi tahmin yeteneğine sahip yöntem yapay sinir ağı olarak saptanmıştır. Yapay sinir ağına ait ROC eğrisi altında kalan alanların söz konusu iki yılda da oldukça yüksek olması, bu yöntemin başarısız ve başarılı işletmeleri ayırım gücünün oldukça iyi olduğunu göstermektedir. Kestirim/eğitim setindeki ROC eğrilerine göre yapılan karşılaştırmada üç ve dört yıl öncesi için en iyi performans diskriminant analizine, beş yıl öncesi içinse yapay sinir ağına aittir. Kontrol/test setinde ise üç ve dört yıl öncesinde en iyi tahmini yapay sinir ağı yaparken, beş yıl öncesinde en iyi performansı lojistik regresyon analizi göstermiştir.

ROC eğrileri kullanılarak yapılan değerlendirme ile geleneksel performans ölçüleriyle yapılan değerlendirme, başarısızlıktan önceki birinci ve ikinci yıl için en iyi model konusunda aynı sonuçları verirken, diğer yıllar için çelişkili sonuçlar üretmişlerdir. Bu durum, aslında bir modelin başarısız ve başarılı işletmeleri birbirinden ayırma gücü yüksek olduğu halde, geleneksel performans ölçüleri tarafından belirlenmiş kopuş değerine göre performansının yanıltıcı şekilde düşük çıkabileceğinin kanıtıdır. Bu durumda geleneksel performans ölçülerinin finansal başarısızlık tahmin modellerinin değerlendirilmesinde uygun bir yöntem olmadığı, mutlaka farklı yanlış sınıflandırma maliyetlerini dikkate alan bir yöntemle değerlendirilmesi gerektiği sonucuna varılmıştır.

Türkiye'deki sanayi işletmelerinin başarısızlıktan beş yıl öncesine kadar tahmininde, tüm modellerin 0,50'nin üzerinde ROC eğrisi altında kalan alana sahip olması, her üç yöntemin de hiçbir araç kullanmadan rastgele tahmin yapmaktan daha iyi sonuçlar ürettiği anlamına gelmektedir.

Başarısızlıktan bir ve iki yıl öncesi için ayırım gücü çok iyi olan, özellikle bir yıl öncesindeki ROC eğrisi altında kalan alanı 0,995 olan yapay sinir ağının mükemmel yakın tahminlerde bulunduğu görülmüştür. İki yıl önceden bir işletmenin durumunu doğru olarak tahmin edebilmek, işletmeyle ilgili pek çok kararın etkin olarak verilmesine olanak sağlayacaktır. Kısa vadeli kredi kararı, mevcut yatırımcıların işletmeyle ilgili durumunu devam ettirip ettirmeme kararı, potansiyel yatırımcının bir işletmeye yatırım yapıp yapmama kararı ve pek çok yönetim kararı için iki yıl yeterli uzunlukta bir süredir. Dolayısıyla da bu tür kararlar için yapay sinir ağlarının kullanılması, kararların etkinliğini artıracaktır.

Başarısızlıktan önceki üçüncü, dördüncü ve beşinci yıllarda ise modellerin eğitim/kestirim seti ve kontrol/test seti üzerinde çelişkili sonuçlar vermesi ihtiyatla değerlendirilmelidir. Ancak, iki yıldan daha uzun süreli tahmin gerektiren kararlarda bile hiçbir araç kullanmadan rastgele tahmin yapmaktansa, herhangi bir model kullanarak tahmin yapmanın daha iyi olduğu sonucuna varılmıştır. Dolayısıyla, uzun vadeli kararlar için bu yöntemler ihtiyatlı bir şekilde değerlendirilmek kaydıyla yardımcı bir araç olarak kullanılabilir.

Yapay sinir ağlarının en büyük eksikliklerinden birisi de kara kutu özelliğidir. Yani istatistikî yöntemlerdeki gibi değişkenlerin önemini gösteren bir model

üretmemektedirler. Üretilen bilgi ađın içinde saklı kalmaktadır. Bu bilgiyi çıkarmaya yönelik çalışmalar yapıldığı bilinmektedir. Daha sonra, bu alandaki gelişmeler takip edilerek, finansal başarısızlık tahmini için oluşturulmuş yapay sinir ađlarındaki bilgiler çıkarılmaya çalışılabilir. Ayrıca, bu çalışmada kullanılan geri yayılım ađları dışındaki olasılıklı yapay sinir ađları, radyal tabanlı yapay sinir ađları, kohonen ađları gibi farklı ađ yapıları, Türkiye'deki işletmelerin finansal başarısızlıklarının tahmini için kullanılabilir. Bu alanda araştırılabilecek diđer bir konu da, bađımsız deđişken olarak 12 aylık mali tablolardan hesaplanan finansal oranları kullanmak yerine, 3 aylık mali tablo verilerini, trendleri ve zaman serilerini kullanmanın finansal başarısızlık tahmini için uygun olup olmadığıdır.

KAYNAKÇA

A) KİTAPLAR VE TEZLER

1. Akgüç; Öztin; Finansal Yönetim, Yenilenmiş 7. Baskı, Avcıol Basım-Yayın, İstanbul, 1998.
2. Aktaş, Ramazan; Endüstri İşletmeleri İçin Mali Başarısızlık Tahmini (Çok Boyutlu Model Uygulaması), Türkiye İş Bankası Kültür Yayınları, Yayın No: 323, Ankara, 1993.
3. Aktaş, Ramazan; Endüstri İşletmeleri İçin Mali Başarısızlık Tahmini-Çok Boyutlu Model Uygulaması, Doktora Tezi, Ankara Üniversitesi, Ankara, 1991.
4. Antonov, Anca; Performance of Modern Techniques for Rating Model Design, Master Thesis, Zürich, 2004.
5. Argyrou, Argyris; Predicting Financial Distress Using Neural Networks: Another Episode to the Serial?, Master of Science Thesis, HANKEN - Swedish School of Economics and Business Administration, Department of Accounting, 2006.
6. Bigus, Joseph B.; Data Mining with Neural Networks: Solving Business Problems from Application Development to Decision Support, McGraw Hill, 1996.
7. Brigham, Eugene F.; Louis C. Gapenski; Financial Management: Theory and Practice, Seventh Edition, The Dryden Press, 1994.
8. Bullock, Rodney Stacey Brooks; Forecasting Bankruptcy to Promote Organizational Survival: A Comparison of Neural Network and Discriminant Analysis Methodologies”, Doctorate Dissertation, Walden University, August 1999.

9. Bker, Semih; Rıza Akođlu; Gven Sevil; Finansal Ynetim, 2. Baskı, Anadolu niversitesi, Eskiehir, 1997.
10. akır, Murat; Firma Baarısızlıđının Dinamiklerinin Belirlenmesinde Makina đrenmesi Teknikleri: Ampirik Uygulamalar ve Karılatırmalı Analiz, Uzmanlık Yeterlilik Tezi, T.C.M.B. İstatistik Genel Mdrlđ, Ankara, 2005.
11. Elmas, etin; Yapay Sinir Ađları (Kuram, Mimari, Eđitim, Uygulama), Sekin Yayıncılık, Ankara, 2003.
12. El-Temtamy, Osama; Bankruptcy Prediction: A Comparative Study on Logit and Neural Networks, Doctorate Thesis, Middle Tennessee State University, 1995.
13. Haykin, Simon; Neural Networks: A Comprehensive Foundation, Second Edition, Prentice Hall International Inc., 1999.
14. Jang, Jaeho; Comparative Analysis of Statistical Methods and Neural Networks for Predicting Life Insurers' Insolvency, Doctorate Thesis, The University of Texas at Austin, 1997.
15. Keskin, Yasemin; İletmelerde Finansal Baarısızlıđın Tahmini, ok Boyutlu Model nerisi ve Uygulaması, Doktora Tezi, Hacettepe niversitesi, Temmuz 2002.
16. Lee, Ki-Dong; Pattern Classification and Clustering Algorithms with Supervised and Unsupervised Neural Networks in Financial Applications, Doctorate Dissertation, Kent State University, 2001.
17. Leech, Nancy L.; Karen C. Barrett; George A. Morgan; SPSS for Intermediate Statistics: Use and Interpretation, Second Edition, Lawrence Erlbaum Associates, Inc, London, 2005.
18. zdamar, Kazım; Paket Programlar ile İstatistiksel Veri Analizi (ok Deđikenli Analizler), 2. Baskı, Kaan Kitabevi, Eskiehir 1999.
19. ztemel, Ercan; Yapay Sinir Ađları, Papatya Yayıncılık, İstanbul, 2003.
20. Sađırođlu, eref; Erkan Bedok; Mehmet Erler; Mhendislikte Yapay Zeka Uygulamaları I-Yapay Sinir Ađları, Ufuk Kitap Kırtasiye Yayıncılık, Kayseri, 2003.

21. Thevnin, Charles; A Comparative Examination of Bankruptcy Prediction: Altman MDA Study Versus Luther ANN Study: A Test of Predictive Strength Between The Two Techniques, Doctorate Dissertation, Nova Southeastern University, 2003.
22. Türko, R. Metin; Finansal Yönetim, Alfa Yayın, İstanbul, 1999.
23. Yıldırım, Tuncay; Mali Oranlar ve Diskriminant Modeli ile Aracı Kurumların Mali Açından Başarılı-Başarısız Olarak Sınıflandırılması (Çok Boyutlu Bir Model Denemesi), Sermaye Piyasası Kurulu Yeterlik Etüdü, 1998.
24. Yıldız, Birol; Finansal Başarısızlığın Öngörülmesinde Yapay Sinir Ağı Kullanımı ve Ampirik Bir Çalışma, Doktora Tezi, Dumlupınar Üniversitesi, Kütahya, 1999.
25. Zhang, G. Peter; Neural Networks in Business Forecasting, Idea Group Publishing, 2004.

B) MAKALELER VE BİLDİRİLER

1. Agarwal, Anurag; “Abductive Networks for Two-Group Classification: A Comparison with Neural Networks”, The Journal of Applied Business Research, Vol. 15, No. 2, 1999, pp.1-12.
2. Aktaş, Ramazan; Mete Doğanay; Birol Yıldız; “Mali Başarısızlığın Öngörülmesi: İstatistiksel Yöntemler ve Yapay Sinir Ağı Karşılaştırması”, Ankara Üniversitesi SBF Dergisi, Cilt 58, Sayı 4, 2003, ss.1-24.
3. Altman Edward I.; Robert A. Eisenbeis; “Financial Applications of Discriminant Analysis: A Clarification”, Journal of Financial and Quantitative Analysis, March 1978, pp.185-195.
4. Altman, Edward I.; “Financial Ratios, Discriminant Analysis and The Prediction of Corporate Bankruptcy”, The Journal of Finance, Vol. XXIII, No. 4, 1968, pp.589-609.
5. Altman, Edward I.; Paul Narayanan; “An International Survey of Business Failure Classification Models”, Financial Markets, Institutions&Instruments, Vol. 6, No. 2, 1997, pp.1-57.

6. Anandarajan, Murugan; Picheng Lee; Asokan Anandarajan; “Bankruptcy Prediction of Financially Stressed Firms: An Examination of the Predictive Accuracy of Artificial Neural Networks”, *Intelligent Systems in Accounting, Finance & Management*, Vol. 10, 2001, pp.69-81.
7. Aziz, Abdul; David C. Emanuel; Gerald H. Lawson; “Bankruptcy Prediction – An Investigation of Cash Flow Based Models”, *Journal of Management Studies*, Vol. 25, No. 5, 1988, pp.419-437.
8. Aziz, Abdul; Gerald H. Lawson; “Cash Flow Reporting and Financial Distress Models: Testing of Hypotheses”, *Financial Management*, Spring 1989, pp.55-63.
9. Barnes, Paul; “The Analysis and Use of Financial Ratios: A Review Article”, *Journal of Business Finance & Accounting*, Vol. 14, No. 4, 1987, pp.449-461.
10. Beaver, William H.; “Alternative Accounting Measures As Predictors of Failure”, *The Accounting Review*, January 1968, pp.113-122.
11. Beaver, William H.; “Financial Ratios as Predictors of Failure”, *Empirical Research in Accounting: Selected Studies*, *Journal of Accounting Research*, Supplement to Vol. 5, 1966, pp.71-111.
12. Bishop, Hannah; Cecilio Mar Molinero; Michael Turner; “Multidimensional Scaling Analysis as a Tool to Explain Company Distress: The Case of Marks&Spencer PLC” (27 Congreso Nacional de Estadística e Investigación Operativa, Lleida), 8-11 de abril de 2003, pp.364-384.
13. Boonyanunta, N.; P. Zeepongsekul; “State of the Art Credit Risk Analysis Model: Comparative Analysis between Statistical Approaches and Neural Network Approaches”, *APORS'2000*, Singapore, 5-7 July, 2000.
14. Brabazon, Anthony; Michael O’Neill; Robin Matthews et Al; “Grammatical Evolution and Corporate Failure Prediction” (Proceedings of the Genetic and Evolutionary Computation Conference (GECCO 2002)), Spector et. al. Eds., New York, July 9-13, 2002, pp.1011-1018.

15. Brockett, Patrick L.; Linda L. Golden; Jaeho Jang et Al; "A Comparison of Neural Network, Statistical Methods, and Variable Choice for Life Insurer's Financial Distress Prediction", *The Journal of Risk and Insurance*, Vol. 73, No. 3, 2006, pp.397-419.
16. Cadden, David T.; "Neural Networks and The Mathematics of Chaos – An Investigation of These Methodologies as Accurate Predictors of Corporate Bankruptcy", *The First International Conference on Artificial Intelligence Applications on Wall Street*, New York, 1991, pp.52-57.
17. Castagna, A. D.; Z. P. Matolcsy; "The Prediction of Corporate Failure: Testing The Australian Experience", *Australian Journal of Management*, Vol. 6, No. 1, 1981, pp.25-30.
18. Charalambous, Chris; Andreas Charitou; Fraso Kaourou; "Comparative Analysis of Artificial Neural Network Models: Application in Bankruptcy Prediction", *Annals of Operations Research*, Vol.99, 2000, pp.403-425.
19. Chen, Kung H.; Thomas A. Shimerda; "An Empirical Analysis of Useful Financial Ratios", *Financial Management*, Spring 1981, pp.51-60.
20. Coakley, James R.; Carol E. Brown; "Artificial Neural Networks in Accounting and Finance: Modeling Issues", *Intelligent Systems in Accounting, Finance & Management*, Vol. 9, 2000, pp.119-144.
21. Coats, Pamela K.; L. Franklin Fant; "A Neural network Approach to Forecasting Financial Distress", *The Journal of Business Forecasting*, Vinter 1991-'92, pp.9-12.
22. Coats, Pamela K.; L. Franklin Fant; "Recognizing Financial Distress Patterns Using a Neural Network Tool", *Financial Management*, Vol. 22, No. 3, 1993, pp.142-155.
23. Deakin, Edward B.; "A Discriminant Analysis of Predictors of Business Failure", *Journal of Accounting Research*, Vol. 10, No. 1, 1972, pp.167-179.
24. DeTienne, Kristen Bell; David H. DeTienne; Shirish A. Joshi; "Neural Networks as Statistical Tools for Business Researchers", *Organizational Research Methods*, Vol.6, No.2, April 2003, pp.236-265.

25. Dietrich, J. Richard; "Discussion of Methodological Issues Related to the Estimation of Financial Distress Prediction Models", *Journal of Accounting Research*, Supplement to Vol. 22, 1984, pp.83-86.
26. Dirican, Ahmet; "Tanı Testi Performanslarının Değerlendirilmesi ve Kıyaslanması", *Cerrahpaşa Tıp Dergisi*, Cilt 32, Sayı 1, 2001, ss.25-30.
27. Dugan, Michael T.; Christine V. Zavgren; "Bankruptcy Prediction Research: A Valuable Instructional Tool", *Issues in Accounting Education*, 1988, pp.48-64.
28. Dunis, Christian L.; J. Alexandros Triantafyllidis; "Alternative Forecasting Techniques for Predicting Company Insolvencies: The UK Example (1980-2001)", *Neural Network World*, No. 3, 2003, 38p.
29. Edmister, Robert O.; "An Empirical Test of Financial Ratio Analysis for Small Business Failure Prediction", *Journal of Financial Quantitative Analysis*, Vol. 2, March 1972, pp.1477-1493.
30. Etheridge, Harlan L.; Ram S. Sriram; "A Comparison of The Relative Costs of Financial Distress Models: Artificial Neural Networks, Logit and Multivariate Discriminant Analysis", *Intelligent Systems in Accounting, Finance and Management*, Vol. 6, 1997, pp. 235-248.
31. Fanning, Kurt M.; Kenneth O. Cogger; "A Comparative Analysis of Artificial Neural Networks Using Financial Distress Prediction", *International Journal of Intelligent Systems in Accounting, Finance and Management*, Vol. 3, 1994, pp.241-252.
32. Flagg, James C.; Gary A. Giroux; "Predicting Corporate Bankruptcy Using Failing Firms", *Review of Financial Economics*, Vol. 1, Issue 1, 1991, pp.67-78.
33. Gentry, James A.; Paul Newbold; David T. Whitford; "Classifying Bankrupt Firms with Funds Flow Components", *Journal of Accounting Research*, Vol. 23, No.1, 1985, pp.146-160.
34. Gentry, James A.; Paul Newbold; David T. Whitford; "Funds Flow Components, Financial Ratios and Bankruptcy", *Journal of Business Finance & Accounting*, Vol. 14, No. 4, 1987, pp.595-606.

35. Gilbert, Lisa R.; Krishnagopal Menon; Kenneth B. Schwartz; "Predicting Bankruptcy For Firms in Financial Distress", *Journal of Business Finance & Accounting*, Vol. 17, No. 1, 1990, pp.161-171.
36. Gratzner, Karl; "Business Failure and The New Economy", EBHA Conference 2001: Business and Knowledge, July 2001, 20p.
37. Grice, John Stephen; Michael T. Dugan; "The Limitations of Bankruptcy Prediction Models: Some Cautions for the Researcher", *Review of Quantitative Finance and Accounting*, Vol. 17, No. 2, 2001, pp.151-166.
38. Gritta, Richard D.; Sergio Davalos; Marcus Wang et Al; "Forecasting Small Air Carrier Bankruptcies Using A Neural Network Approach: A Preliminary Analysis", *Journal of Financial Management and Analysis*, Vol. 13, No.1, January 2000, pp.44-49.
39. Hekanaho, Jukka; Barbro Back; Kaisa Sere; Teija Laitinen; "Analysing Bankruptcy Data with Multiple Methods", In Proc. of the 4th International Workshop on Multistrategy Learning (MSL'98), Brescia, Italy, June 1998, 7p.
40. Hu, Yi-Chiang; Jake Ansell; "Developing Financial Distress Prediction Models", Credit 2006 Conference, Scuola Grande, Venice, Italy, 25th-26th September, 22p.
41. Hunter, John; Natalia Isachenkova; "Aggregate Economy Risk and Company Failure: An Examination of UK Quoted Firms in the Early 1990s", BAA 2003 Annual Conference, Manchester, April 2004, 32p.
42. Hunter, John; Natalia Isachenkova; "Failure Risk: A Comparative Study of UK and Russian Firms", *Journal of Policy Modeling*, Vol. 23, 2001, pp.511-521.
43. Iwan, Mohamad; "Bankruptcy Prediction Model with Zeta_c Optimal Cut-Off Score to Correct Type I Errors", *Gadjah Mada International Journal of Business*, Vol.7, No.1, January-April 2005, pp.41-68.
44. Jain, Bharat A.; Barin N. Nag; "Performance Evaluation of Neural Network Decision Models", *Journal of Management Information Systems*, Vol.14, No.2, Fall-1997, pp.201-216.

45. Karels, Gordon V.; Arun J. Prakash; “Multivariate Normality and Forecasting of Business Bankruptcy”, *Journal of Business Finance & Accounting*, Vol. 14, No. 4, 1987, pp.573-593.
46. Keasey K.; R. Watson; “Non-Financial Symptoms an the Prediction of Small Company Failure: A Test of Argenti’s Hypotheses”, *Journal of Business Finance & Accounting*, Vol. 14, No. 3, 1987, pp.335-354.
47. Keasey, Kevin; Robert Watson; “Financial Distress Prediction Models: A Review of Their Usefulness”, *British Journal of Management*, Vol. 2, 1991, pp.89-102.
48. Kiviluoto, Kimmo; “Predicting Bankruptcies with The Self-Organizing Map”, *Neurocomputing*, Vol. 21, 1998, pp. 191-201.
49. Krishnaswamy, C. R.; Erika W. Gilbert; Mary M. Pashley; “Neural Network Applications in Finance: A Practical Introduction”, *Financial Practice and Education*, 2000, pp.75-84.
50. Kumar, P. Ravi; V. Ravi; “Bankruptcy Prediction in Banks and Firms via Statistical and Intelligent Techniques – A Review”, *European Journal of Operational Research*, Vol.180, 2007, pp.1-28.
51. Kutman, Önder; “Türkiye’deki Şirketlerde Erken Uyarı Göstergelerinin Araştırılması”, *Doğuş Üniversitesi Dergisi*, Vol. 4, 2001, pp.59-70.
52. Laitinen, Erkki K.; Teija Laitinen; “Bankruptcy Prediction Application of the Taylor’s Expansion in Logistic Regression”, *International Review of Financial Analysis*, Vol:9, 2000, pp.327-349.
53. Laitinen, Teija; Maria Kankaanpää; “Comparative Analysis of Failure Prediction Methods: The Finnish Case”, *The European Accounting Review*, Vol. 8, No. 1, 1999, pp.67-92.
54. Lee, Kidong; David Booth; Pervaiz Alam; “A Comparison of Supervised and Unsupervised Neural Networks in Predicting Bankruptcy of Korean Firms”, *Expert Systems with Applications*, Vol. 29, 2005, pp.1-16.

- 55.** Lee, Kidong; David Booth; Pervaiz Alam; “Backpropagation and Kohonen Self-Organizing Feature Map in Bankruptcy Prediction”, in *Neural Networks in Business Forecasting*, Idea Group, Inc., Chapter 8, 2004, 350p.
- 56.** Li, Xiaotong; Jatinder N. D. Gupta; “Neural Networks in Financial Failure Prediction-A Revisit”, *Proceedings of the Annual Decision Sciences Institute Conference*, San Diego, 2002, pp.233-238.
- 57.** Lin, Feng Yu; Sally McClean, “The Prediction of Financial Distress Using a Cost Sensitive Approach and Prior Probabilities”, *17th International Conference on Machine Learning Workshop on Cost Sensitive Learning*, Stanford University, USA, 2000, 8p.
- 58.** Mensah, Yaw M.; “An Examination of the Stationarity of Multivariate Bankruptcy Prediction Models: A Methodological Study”, *Journal of Accounting Research*, Vol 22, No 1, Spring 1984, pp.380-395.
- 59.** Meyer, Paul A.; Howard W. Pifer; “Prediction of Bank Failures”, *The Journal of Finance*, Vol. 25, No. 4, September 1970, pp.853-868.
- 60.** Moses, D. O.; S. S. Liao; “On Developings Model for Failure Prediction”, *Journal of Commercial Bank Lending*, 1987, Vol. 69, pp.27-38.
- 61.** Mossman, Charles E.; Geoffrey G. Bell; L. Mick Swartz et Al; “An Empirical Comparison of Bankruptcy Models”, *The Financial Review*, Vol. 33, 1998, pp.35-54.
- 62.** Moyer, R. Charles; “Forecasting Financial Failure: A Re-Examination”, *Financial Management*, Spring 1977, pp.11-17.
- 63.** Nanda, Sudhir; Parag Pendharkar; “Linear Models for Minimizing Misclassification Costs in Bankruptcy Prediction”, *International Journal of Intelligent Systems in Accounting, Finance & Management*, Vol. 10, 2001, pp.155-168.
- 64.** Neophytou, Evridiki; Andreas Charitou; Chris Charalambous; “Predicting Corporate Failure: Empirical Evidence for the UK”, *European Accounting Review*, Vol. 13, No. 3, 2004, pp.465-497.

- 65.** Nguyen, Huong Giang; “Using Neural Network in Predicting Corporate Failure”, *Journal of Social Sciences*, Vol. 1, No. 4, 2005, pp.199-202.
- 66.** O’Leary, Daniel E.; “Using Neural Networks to Predict Corporate Failure”, *International Journal of Intelligent Systems in Accounting, Finance & Management*, Vol. 7, 1998, pp.187-197.
- 67.** Odom, Marcus D.; Ramesh Sharda.; “A Neural Network for Bankruptcy Prediction”, *IJCNN International Joint Conference on Neural Networks*, Vol. 2, San Diego, CA, 1990, pp. 163-167.
- 68.** Ohlson, James A.; “Financial Ratios and the Probabilistic Prediction of Bankruptcy”, *Journal of Accounting Research*, Vol. 18, No. 1, 1980, pp.109-131.
- 69.** Platt, Harlan D.; Marjorie B. Platt; “Predicting Corporate Financial Distress: Reflections on Choice-Based Sample Bias”, *Journals of Economics and Finance*, Vol. 26, No. 2, 2002, pp.184-199.
- 70.** Pocięcha, Józef; “Discriminant Methods for Bankruptcy Prediction – Theory and Applications”, *Ekonomika*, Vol. 72, 2005, pp.1-7.
- 71.** Pompe, P. P. M.; A. J. Feelders; “Using Machine Learning, Neural Networks, and Statistics to Predict Corporate Bankruptcy”, *Microcomputers in Civil Engineering*, Vol. 12, 1997, pp.267-276.
- 72.** Raghupathi, Wullianallur; Lawrence L. Schkade; Bapi S. Raju; “A Neural Network Application for Bankruptcy Prediction”, *Proceedings of the 24th Annual Hawaii International Conference on Systems Sciences*, Vol. IV, 1991, , pp. 147-155.
- 73.** Sarle, Warren S.; “Neural Networks and Statistical Models”, *Proceedings of the Nineteenth Annual SAS Users Group International Conference*, April, 1994, 13p.
- 74.** Sen, Tarun K.; Parviz Ghandforoush and Charles T. Stivason; “Improving Prediction of Neural Networks: A Study of Two Financial Prediction Tasks”, *Journal of Applied Mathematics and Decision Sciences*, Vol.8, No.4, 2004, pp.219-233.

- 75.** Serrano-Cinca, Carlos; “Feedforward Neural Networks in the Classification of Financial Information”, *The European Journal of Finance*, Vol.3, No.3, 1997, pp.183-202.
- 76.** Serrano-Cinca, Carlos; “Self Organizing Neural Networks for Financial Diagnosis”, *Decision Support Systems*, Vol. 17, 1996, pp.227-238.
- 77.** Shah, Jaymeen R.; Mirza B. Murtaza; “A Neural Network Based Clustering Procedure for Bankruptcy Prediction”, *American Business Review*, June 2000, pp.80-86.
- 78.** Sharma, Divesh S.; “The Role of Cash Flow Information in Predicting Corporate Failure: The State of the Literature”, *Managerial Finance*, Vol. 27, No. 4, 2001, pp. 3-28.
- 79.** Sharma, Subhash; Vijay Mahajan; “Early Warning Indicators of Business Failure”, *Journal of Marketing*, Vol. 44, Fall 1980, pp.80-89.
- 80.** Sheppard, Jerry Paul; “The Dilemma of Matched Pairs and Diversified Firms in Bankruptcy Prediction Models”, *The Mid-Atlantic Journal of Business*, Vol.30, No.1, March-1994, pp.9-25.
- 81.** Shin, Kyung-Shik; Yong-Joo Lee; “A Genetic Algorithm Application in Bankruptcy Prediction Modeling”, *Expert Systems with Applications*, Vol. 23, No. 3, 1 October 2002, pp.321-328.
- 82.** Tamari, M.; “Financial Ratios as a Means of Forecasting Bankruptcy”, *Management International Review*, Vol. 4, Winter 1966, pp.15-21.
- 83.** Tan, Clarence N. W.; Herlina Dihadjo; “A Study on Using Artificial Neural Networks to Develop An Early Warning Predictor for Credit Union Financial Distress with Comparison to the Probit Model”, *Managerial Finance*, Vol. 27, No. 4, 2001, pp. 56-77.
- 84.** Tucker, John; “Neural Networks Versus Logistic Regression in Financial Modelling: A Methodological Comparison”, *Proceedings of the 1996 World First*

Online Workshop on Soft Computing (WSC1), Nagoya University, Japan, August 19-30, 1996, 6p.

85. Uğurlu, Mine ve Hakan Aksoy; “Prediction of Corporate Financial Distress in an Emerging Market: The Case of Turkey”, *Cross Cultural Management: An International Journal*, Vol. 13, No. 4, 2006, pp.277-295.

86. Warner, Brad; Misra Manavendra; “Understanding Neural Networks as Statistical Tools”, *The American Statistician*, Vol:50, 1996, pp.284-293.

87. Weiss, Lawrence A.; “The Impact of Incorporating the Cost of Errors into Bankruptcy Prediction Models” (19th Annual Congress of the European Accounting Association), Bergen, Norway, 1996, 14p.

88. Yang, Z. R.; Marjorie B. Platt; Harlan D. Platt; “Probabilistic Neural Networks in Bankruptcy Prediction”, *Journal of Business Research*, Vol. 44, 1999, pp.67-74.

89. Yang, Zheng Rong; “A New Method for Company Failure Prediction Using Probabilistic Neural Networks”, 8th International Conference on Neural Information Processing (ICONIP-2001), Shanghai, China, 14-18 November 2001, 6p.

90. Zapranis, Achilleas; Demetrios Ginoglou; “Forecasting Corporate Failure with Neural Network Approach: The Greek Case”, *Journal of Financial Management and Analysis*, Vol. 13, No. 2, 2000, pp.11-20.

91. Zavgren, Christine V.; George E. Friedman, “Are Bankruptcy Prediction Models Worthwhile? An Application in Securities Analysis”, *Management International Review*, Vol. 28, No.1, 1988, pp.34-44.

92. Zhang, Guoqiang; Michael Y. Hu; B. Eddy Patuwo; Daniel C. Indro; “Artificial Neural Networks in Bankruptcy Prediction: General Framework and Cross-Validation Analysis”, *European Journal of Operational Research*, Vol. 116, 1999, pp.16-32.

93. Zmijewski, Mark E.; “Methodological Issues Related to the Estimation of Financial Distress Prediction Models”, *Journal of Accounting Research*, Supplement to Vol. 22, 1984, pp.59-82.

94. Zurada, Jozef M.; Benjamin P. Foster; Terry J. Ward et Al; "Neural Networks Versus Logit Regression Models for Predicting Financial Distress Response Variables", The Journal of Applied Business Research, Vol. 15, No. 1, 1998, pp.21-29.

C) İNTERNET KAYNAKLARI

1. Andreev, Yuriy Andreev; "Predicting Financial Distress of Spanish Companies", III Jornada De Pre-Comunicaciones A Congresos De Economia Y Administración De Empresas, 29 de Junio de 2006, 22p. Erişim Adresi: <http://selene.uab.es/dep-economia-empresa/Jornadas/Papers/2006/Andreev.pdf>.
2. Atiya, Amir F.; "Bankruptcy Prediction for Credit Risk Using Neural Networks: A Survey and New Results", IEEE Transactions On Neural Networks, Vol. 12, No. 4, July 2001, pp.929-935, Erişim Adresi: <http://alumnus.caltech.edu/~amir/bankr.pdf>.
3. Aziz, M. Adnan; Humayon A. Dar; "Predicting Corporate Bankruptcy: Whither do We Stand?" (3rd Annual Meeting of the European Economics and Finance Society "World Economy and European Integration"), University of Gdansk, 13-16 May 2004, 51p., Erişim Adresi: <http://gnu.univ.gda.pl/~eefs/pap/aziz.doc>.
4. Back, B; G. Oosterom; K. Sere; M. Van Wezel; "A Comparative Study of Neural Networks in Bankruptcy Prediction", Proceedings of the 10th Conference on Artificial Intelligence Research in Finland, Turku, Finland, 1994, 14p. Erişim Adresi: <http://citeseer.ist.psu.edu/110309.html>.
5. Back, Barbro; Kaisa Sere; Michiel C. Van Wezel; "Choosing the Best Set of Bankruptcy Predictors", Proceedings of the First Nordic Workshop on Genetic Algorithms and Their Applications (INWGA), Proceedings of the University of Vaasa, Reports 2, Vaasa, Finland, 1995, 20p. Erişim Adresi: <http://citeseer.ist.psu.edu/27743.html>.
6. Back, Barbro; Teija Laitinen; Jukkapekka Hekanaho; Kaisa Sere; "The Effects of Sample Size on Different Failure Prediction Methods", Technical Report No.155, Turku Centre for Computer Science, 1997, 26p, Erişim Adresi: <http://citeseer.ist.psu.edu/88905.html>.

7. Back, Barbro; Teija Laitinen; Kaisa Sere; Michiel van Wezel; “Choosing Bankruptcy Predictors Using Discriminant Analysis, Logit Analysis, and Genetic Algorithms”, Technical Report No.40, Turku Centre for Computer Science, 1996, 20p, Eriřim Adresi: <http://www.eyepredictor.com/pdf/back1996.pdf>.
8. Balcaen, Sofie; Hubert Ooghe; “35 Years of Studies on Business Failure: An Overview of the Classical Statistical Methodologies and Their Related Problems”, Universiteit Gent Working Paper: 2004/248, June 2004, 62p., Eriřim Adresi: http://www.claristat.org/wp_04_248.pdf.
9. Balcaen, Sofie; Hubert Ooghe; “Alternative Metodologies in Studies on Business Failure: Do They Produce Better Results Than The Classic Statistical Methods?”, Vlerick Leuven Gent Working Paper: 2004/16, 2004, 44p., Eriřim Adresi: <http://www.vlerick.be/en/2663-VLK/version/default/part/AttachmentData/data/vlgms-wp-2004-16.pdf>.
10. Boritz, J. E.; J. Sun; “Predicting Going Concern Risks in Canada”, School of Accountancy Working Paper, January 2004, Submitted to ASAC Conference, 36p., Eriřim Adresi: http://accounting.uwaterloo.ca/seminars/old_papers/efrim_boritz_predicting_gcr_jan_2004.pdf.
11. Cerny, Portia A.; “Data Mining and Neural Networks from A Commercial Perspective”, the 36th Annual ORSNZ Conference, University of Canterbury, Christchurch, NZ, 2001, 10p. Eriřim Adresi: <http://www.esc.auckland.ac.nz/-organisations/orsnz/-conf36/papers/Cerny.pdf>.
12. Charitou, Andreas; Lenos Trigeorgis; “Option-Based Bankruptcy Prediction”, EFMA (European Financial Management Journal) 2000 Athens, 2000, 27p. Eriřim Adresi: http://papers.ssrn.com/sol3/papers.cfm?abstract_id=248709#PaperDownload.
13. Demir, Hüseyin; “İřletmelerde Başarısızlığın Nedenleri ve Çıkıř Yolları”, Dıř Ticaret Dergisi, Temmuz 1997, Eriřim Adresi: <http://www.foreigntrade.gov.tr/ead/-DTDERGI/tem97/4.htm>.
14. Dorsey, Robert E.; Robert O. Edmister; John D. Johnson; “Bankruptcy Prediction Using Artificial Neural Systems”, Working Paper, College of Business, University of

Mississippi, 1995, 72p, Eriřim Adresi: <http://tide.it.bond.edu.au/inf361/olemisdata/-bankrupt.pdf>.

15. Holland, Rob; “Planning Against A Business Failure”, Agriculturel Development Center, Info#24, October 1998, <http://cpa.utk.edu/pdf/files/adc24.pdf>.

16. Hürriyet Gazetesi <http://www.hurriyet.com.tr>

17. İstanbul Menkul Kıymetler Borsası Web Sayfası <http://www.imkb.gov.tr>

18. Perez, Muriel; “Neural Networks Applications in Bankruptcy Forecasting: A State of The Art”, ESIT ‘99 (European Symposium on Intelligent Techniques), Orthodox Acedemy od Crete, Greece, June 3-4, 1999, 6p, Eriřim Adresi: http://www.erudit.de/erudit/events/esit99/12520_p.pdf.

19. Sermaye Piyasası Kurulu Web Sayfası <http://www.spk.gov.tr>

20. Shachmurove, Yachanan; “Applying Artificial Neural Networks to Business, Economics and Finance”, CARESS Working Papers, University of Pennsylvania, 2002, 47p., Eriřim Adresi: <http://www.econ.upenn.edu/Centers/CARESS/CARESSpdf/02-08.pdf>.

21. Türkiye Cumhuriyeti Merkez Bankası Web Sayfası <http://www.tcmb.gov.tr>

22. Tyree, Eric W.; J. A. Long; “Bankruptcy Prediction Models: Probabilistic Neural Networks Versus Discriminant Analysis and Backpropagation Neural Networks”, City University, 1997, 27p., Eriřim Adresi: <http://citeseer.ist.psu.edu/155450.html>.

EKLER

EK-1 UYGULAMA İÇİN ÖRNEK SETLERİNİ OLUŞTURAN İŞLETMELER

KESTİRİM/EĞİTİM SETİ

Borsa Kodu	Şirketin Adı	Başarısız/Başarılı*
ADANA	Adana Çimento	1
ADEL	Adel Kalemcilik	1
AFYON	Afyon Çimento	1
AGIDA	Anadolu Gıda	1
AKALT	Akal Tekstil	1
AKCNS	Akçansa Çimento	1
AKIPD	Aksu İplik Dokuma ve Boya Apre Fabr.	1
AKSA	Aksa Akrilik Kimya	1
ALCAR	Alarko Carrier	1
ALTIN	Altinyıldız	1
ALYAG	Altındağ Yağ	0
ANBRA	Anadolu Biracılık Malt ve Gıda	1
ARAT	Arat Tekstil	0
ARCLK	Arçelik	1
ARDEM	Ardem	1
ARSAN	Arsan Tekstil	0
ASLAN	Aslan Çimento	0
ASUZU	Anadolu Isuzu	0
ATEKS	Akın Tekstil	1
BANVT	Banvit	1
BEKO	Beko Elektronik	1
BERDN	Berdan Tekstil	0
BFREN	Bosch Fren	1
BOLUC	Bolu Çimento	1
BOSSA	Bossa	1
BRISA	Brisa	1
BRMEN	Birlik Mensucat	0
BRSAN	Borusan Boru	1
BSOKE	Batı Söke Çimento	1
BSPRO	Bosch Profilo	1
BTCIM	Batıçim	1
BURCE	Burçelik	0
BYRBY	Bayraklı Boya	0
BYSAN	Boyasan Tekstil	0
CBSBO	ÇBS Boya Kimya	0
CELHA	Çelik Halat	0
CEMTS	Çemtaş	0
CEYLN	Ceylan Giyim	1
CIMSA	Çimsa	1
CMENT	Çimentaş	1
DARDL	Dardanel	0
DENCM	Denizli Cam	1
DERIM	Derimod	0
DITAS	Ditaş Doğan	1

* "1" Başarılı İşletmeler, "0" Başarısız İşletmeler

Ek-1 Devamı

DMSAS	Demisaş Döküm	0
DOBUR	Doğan Burda Rizzoli Dergi Yayıncılık	1
DOKTS	Döktaş	0
DUROF	Duran Ofset	0
DYOBY	Yasaş	0
ECILC	Eczacıbaşı İlaç	1
ECYAP	Eczacıbaşı Yapı	1
EDIP	Edip İplik	0
EGBRA	Ege Biracılık ve Malt San.	1
EGEEN	Ege Endüstri	1
EGGUB	Ege Gübre	1
EGSER	Ege Seramik	0
EMKEL	Emek Elektrik	0
EMNIS	Eminiş Ambalaj	0
EPLAS	Ege Plastik	0
ERBOS	Erbosan	1
ERCYS	Erciyas Biracılık	0
EREGL	Ereğli Demir Çelik	0
ERSU	Ersu	0
ESEMS	Esem Spor	0
FENIS	Feniş Alüminyum	1
FRIGO	Frijo Pak	0
FROTO	Ford Otosan	1
GEDIZ	Gediz İplik	0
GENTS	Gentaş	1
GOLTS	Göller Bölgesi Çimento	1
GOODY	Good-Year	0
GORBN	Gorbon Işıl	0
GUBRF	Gübre Fabrikaları AŞ	1
GUMUS	Gümüşsuyu	0
GUNAY	Güney Biracılık	1
HEKTS	Hektaş	1
HURGZ	Hürriyet Gazetecilik	1
HZNDR	Haznedar Ateş Tuğla	1
IHEVA	İhlas Ev Aletleri	0
ISAMB	Işıklar Ambalaj/Çumra Kağıt	0
IZMDC	İzmir Demir Çelik	0
KAPLM	Kaplamin Ambalaj	0
KARSN	Karsan	0
KENT	Kent Gıda	0
KERVT	Kerevitaş Gıda	0
KLBMO	Kelebek Mobilya	0
KNFRT	Konfrut Gıda	0
KOTKS	Koniteks	0
LUKSK	Lüks Kadife	0
MAKTK	Makina Takım	0

* "1" Başarılı İşletmeler, "0" Başarısız İşletmeler

Ek-1 Devamı

KONTROL/TEST SETİ

Borsa Kodu	Şirketin Adı	Başarısız/Başarılı*
IZOCM	İzocam	1
KLMSN	Klimasan	1
KORDS	Kordsa Sabancı Dupont	1
KUTPO	Kütahya Porselen	1
MARET	Maret	0
MERKO	Merko Gıda	0
MRDIN	Mardin Çimento	1
NERGS	Nergis	0
OLMKS	Olmuksa	1
OYSAC	Oysa Niğde Çimento	1
PETKM	Petkim	1
PIMAS	Pimaş	0
PINSU	Pınar Su	0
POLYL	Polylen	0
PRTAS	ÇBS Printaş	0
RKSEV	Raks Ev Aletleri	0
SABAH	Sabah Yayıncılık	1
SELGD	Selçuk Gıda	0
SERVE	Serve Kırtasiye	1
SKTAS	Söktaş	0
SONME	Sönmez Filament	0
TATKS	Tat Konservecilik	1
TIRE	Tire Kutsan	1
TUDDF	Türk Demir Döküm	1
TUMTK	Tümteks Tekstil	0
UNTAR	Ünal Tarım	0
USAK	Uşak Seramik	0
VAKKO	Vakko Hazır Giyim	1
VESTL	Vestel	1
VKING	Viking Kağıt	0

* “1” Başarılı İşletmeler, “0” Başarısız İşletmeler

Ek-1 Devamı

ONAYLAMA SETİ

Borsa Kodu	Şirketin Adı	Başarısız/Başarılı*
KARTN	Kartonsan	1
KONYA	Konya Çimento	1
KRTEK	Karsu Tekstil	1
LIOYS	Lio Yağ San.	1
MDRNU	Mudurnu Tavukçuluk	0
MEGES	Meges Boya	0
MEMSA	Mensa Mensucat	0
MILYT	Milliyet Gazetecilik	0
NUHCM	Nuh Çimento	1
OTKAR	Otokar	1
PARSN	Parsan	0
PASTA	Pastavilla	1
PENGD	Penguen Gıda	0
PNSUT	Pınar Süt	1
RAKSE	Raks Elektronik	0
SARKY	Sarkuysan	1
SASA	Sasa	0
SIFAS	Sifaş Tekstil	0
SNPAM	Sönmez Pamuklu	0
SODA	Soda Sanayi	1
TBORG	Türk Tuborg	1
TOASO	Tofaş Oto Fabrika	0
TRKCM	Trakya Cam	1
TUKAS	Tukaş	1
UKIM	Uki Konfeksiyon	0
UNYEC	Ünye Çimento	0
UZEL	Uzel Makina	0
VANET	Van Et	1

* "1" Başarılı İşletmeler, "0" Başarısız İşletmeler

EK-2 BAĞIMSIZ DEĞİŞKEN OLARAK KULLANILAN FİNANSAL ORANLARIN FORMÜLLERİ

ORAN	FORMÜLÜ
A. LİKİDİTE ORANLARI	
X1: Cari Oran	Dönen Varlıklar / Kısa Vadeli Yabancı Kaynaklar
X2: Asit-Test Oranı	(Dönen Varlıklar – Stoklar) / Kısa Vadeli Yabancı Kaynaklar
X3: Nakit Oranı	(Hazır Değerler + Menkul Kıymetler) / Kısa Vadeli Yabancı Kaynaklar
X4: Stokların Toplam Varlıklara Oranı	Stoklar / Aktif Toplamı
X5: Kısa Vadeli Alacakların Toplam Varlıklara Oranı	(Kısa Vadeli Ticari Alacaklar + Diğer Kısa Vadeli Alacaklar) / Aktif Toplamı
B. FİNANSAL YAPI ORANLARI	
X6: Finansal Kaldıraç Oranı	(Kısa Vadeli Yabancı Kaynaklar + Uzun Vadeli Yabancı Kaynaklar) / Pasif Toplamı
X7: Kısa Vadeli Yabancı Kaynakların Toplam Kaynaklara Oranı	Kısa Vadeli Yabancı Kaynaklar / Pasif Toplamı
X8: Uzun Vadeli Yabancı Kaynakların Toplam Kaynaklara Oranı	Uzun Vadeli Yabancı Kaynaklar / Pasif Toplamı
X9: Uzun Vadeli Yabancı Kaynakların Devamlı Sermayeye Oranı	Uzun Vadeli Yabancı Kaynaklar / (Uzun Vadeli Borçlar + Özsermaye)
X10: Duran Varlıkların Özsermayeye Oranı	Duran Varlıklar / Özsermaye
X11: Dönen Varlıkların Toplam Varlıklara Oranı	Dönen Varlıklar / Aktif Toplamı
C. FAALİYET ORANLARI	
X12: Hazır Değerler Devir Hızı	Net Satışlar / (Hazır Değerler + Menkul Kıymetler)
X13: Stok Devir Hızı	Satışların Maliyeti / Ortalama Stoklar
X14: Alacak Devir Hızı	Satışlar / (Kısa Vadeli Ticari Alacaklar + Uzun Vadeli Ticari Alacaklar)
X15: Dönen Varlık Devir Hızı	Net Satışlar / Dönen Varlıklar
X16: Duran Varlık Devir Hızı	Net Satışlar / Duran Varlıklar
X17: Özsermaye Devir Hızı	Net Satışlar / Özsermaye
X18: Toplam Varlık Devir Hızı	Net Satışlar / Aktif Toplamı
D. KARLILIK ORANLARI	
X19: Özsermayenin Karlılığı Oranı (Mali Rantabilite Oranı)	Net Dönem Karı veya Zararı / Özsermaye
X20: Faiz ve Vergi Öncesi Karın Toplam Kaynaklara Oranı (Ekonomik Rantabilite Oranı)	Faiz ve Vergi Öncesi Kar / Pasif Toplamı
X21: Toplam Varlıkların Karlılığı Oranı	Net Dönem Karı veya Zararı / Toplam Varlıklar
X22: Faaliyet Kar Marjı	Faaliyet Karı veya Zararı / Net Satışlar
X23: Brüt Kar Marjı	Brüt Kar veya Zarar / Net Satışlar
X24: Net Kar Marjı	Net Dönem Karı / Net Satışlar
X25: Finansman Giderlerinin Net Satışlara Oranı	Finansman Giderleri / Net Satışlar
X26: Finansman Giderlerini Karşılama Oranı	Faiz ve Vergi Öncesi Kar / Finansman Giderleri

EK-3 DISKRİMİNANT ANALİZİ ÇIKTILARI

Discriminant

Analysis Case Processing Summary

Unweighted Cases		N	Percent
Valid		90	100,0
Excluded	Missing or out-of-range group codes	0	,0
	At least one missing discriminating variable	0	,0
	Both missing or out-of-range group codes and at least one missing discriminating variable	0	,0
	Total	0	,0
Total		90	100,0

Stepwise Statistics

Variables Entered/Removed^{a,b,c,d}

Step	Entered	Wilks' Lambda							
		Statistic	df1	df2	df3	Exact F			
						Statistic	df1	df2	Sig.
1	VAR00010	,735	1	1	88,000	31,755	1	88,000	,000
2	VAR00024	,607	2	1	88,000	28,210	2	87,000	,000
3	VAR00012	,563	3	1	88,000	22,290	3	86,000	,000
4	VAR00002	,534	4	1	88,000	18,555	4	85,000	,000

At each step, the variable that minimizes the overall Wilks' Lambda is entered.

- Maximum number of steps is 52.
- Minimum partial F to enter is 3.84.
- Maximum partial F to remove is 2.71.
- F level, tolerance, or VIN insufficient for further computation.

Summary of Canonical Discriminant Functions

Eigenvalues

Function	Eigenvalue	% of Variance	Cumulative %	Canonical Correlation
1	,873(a)	100,0	100,0	,683

a First 1 canonical discriminant functions were used in the analysis.

Wilks' Lambda

Test of Function(s)	Wilks' Lambda	Chi-square	df	Sig.
1	,534	53,976	4	,000

Ek-3 Devamı

Canonical Discriminant Function Coefficients

	Function 1
VAR00002	-,672
VAR00010	1,563
VAR00012	,002
VAR00024	-9,262
(Constant)	-,176

Unstandardized coefficients

Functions at Group Centroids

	Function 1
VAR00027	
,00	,924
1,00	-,924

Unstandardized canonical discriminant functions evaluated at group means

Classification Statistics**Classification Processing Summary**

Processed		90
Excluded	Missing or out-of-range group codes	0
	At least one missing discriminating variable	0
Used in Output		90

Classification Results(b,c)

			Predicted Group Membership		Total
			,00	1,00	,00
Original	Count	,00	36	9	45
		1,00	8	37	45
	%	,00	80,0	20,0	100,0
		1,00	17,8	82,2	100,0
Cross-validated(a)	Count	,00	35	10	45
		1,00	9	36	45
	%	,00	77,8	22,2	100,0
		1,00	20,0	80,0	100,0

a Cross validation is done only for those cases in the analysis. In cross validation, each case is classified by the functions derived from all cases other than that case.

b 81,1% of original grouped cases correctly classified.

c 78,9% of cross-validated grouped cases correctly classified.

EK-4 LOJİSTİK REGRESYON ANALİZİ ÇIKTILARI**Logistic Regression****Case Processing Summary**

Unweighted Cases(a)		N	Percent
Selected Cases	Included in Analysis	90	100,0
	Missing Cases	0	,0
	Total	90	100,0
Unselected Cases		0	,0
Total		90	100,0

a. If weight is in effect, see classification table for the total number of cases.

Dependent Variable Encoding

Original Value	Internal Value
,00	0
1,00	1

Block 1: Method = Forward Stepwise (Conditional)**Omnibus Tests of Model Coefficients**

		Chi-square	df	Sig.
Step 1	Step	34,076	1	,000
	Block	34,076	1	,000
	Model	34,076	1	,000
Step 2	Step	12,935	1	,000
	Block	47,012	2	,000
	Model	47,012	2	,000
Step 3	Step	9,712	1	,002
	Block	56,724	3	,000
	Model	56,724	3	,000

Ek-4 Devami

Variables in the Equation

	B	S.E.	Wald	df	Sig.	Exp(B)	95,0% C.I. for EXP(B)		
							Lower	Upper	
Step 1 _a	VAR00010	-4,299	1,009	18,139	1	,000	,014	,002	,098
	Constant	3,521	,819	18,463	1	,000	33,824		
Step 2 _b	VAR00010	-5,385	1,260	18,263	1	,000	,005	,000	,054
	VAR00012	-,007	,004	3,998	1	,046	,993	,986	1,000
	Constant	4,798	1,062	20,401	1	,000	121,212		
Step 3 _c	VAR00010	-5,221	1,408	13,755	1	,000	,005	,000	,085
	VAR00012	-,007	,004	2,549	1	,110	,994	,986	1,001
	VAR00024	17,932	6,591	7,401	1	,007	6E+007	150,363	3E+013
	Constant	3,531	1,188	8,842	1	,003	34,167		

a. Variable(s) entered on step 1: VAR00010.

b. Variable(s) entered on step 2: VAR00012.

c. Variable(s) entered on step 3: VAR00024.

**EK-5 BAŞARISIZLIKTAN 1 YIL ÖNCESİ İÇİN DİSKRİMİNANT ANALİZİ,
LOJİSTİK REGRESYON VE YAPAY SINIR AĞLARI MODELLERİNİN
SONUÇLARI VE TAHMİNLERİ**

Kestirim/Eğitim Seti

Şirket Kodu	Başarı Durumu	Diskriminant Skoru	DA Tahmini	Lojistik Regresyon Olasılık Oranı	LR Tahmini	Yapay Sinir Ağı Çıktısı	YSA Tahmini
ADANA	1	-1,68691	1	0,946729	1	1,038037	1
ADEL	1	-0,92332	1	0,969289	1	1,024062	1
AFYON	1	-1,72704	1	0,972926	1	1,043324	1
AGIDA	1	-1,90539	1	0,934332	1	1,049502	1
AKALT	1	-0,15753	1	0,684099	1	0,54696	1
AKCNS	1	-0,92022	1	0,725987	1	0,821626	1
AKIPD	1	-0,8618	1	0,696422	1	0,927279	1
AKSA	1	-1,9362	1	0,98535	1	1,053814	1
ALCAR	1	-1,93817	1	0,976787	1	1,053692	1
ALTIN	1	0,19476	0	0,445424	0	0,743451	1
ALYAG	0	1,766991	0	0,008412	0	-0,05263	0
ANBRA	1	-0,21475	1	0,651334	1	1,01692	1
ARAT	0	1,048795	0	0,046631	0	-0,05074	0
ARCLK	1	-1,30407	1	0,923603	1	1,047619	1
ARDEM	1	-1,14367	1	0,827406	1	1,052293	1
ARSAN	0	-0,32879	1	0,566266	1	0,205757	0
ASLAN	0	0,820552	0	0,094609	0	-0,04437	0
ASUZU	0	-0,17417	1	0,772552	1	0,350612	0
ATEKS	1	-0,02005	1	0,610941	1	0,701308	1
BANVT	1	-2,74003	1	0,996569	1	1,054273	1
BEKO	1	0,019243	0	0,599419	1	0,452645	0
BERDN	0	0,911379	0	0,15361	0	0,091317	0
BFREN	1	-2,87712	1	0,991357	1	1,054649	1
BOLUC	1	-2,47114	1	0,987412	1	1,053636	1
BOSSA	1	-0,75086	1	0,872974	1	0,861741	1
BRISA	1	-1,69873	1	0,960996	1	1,050976	1
BRMEN	0	0,116465	0	0,578273	1	0,460623	0
BRSAN	1	0,146242	0	0,465207	0	0,735746	1
BSOKE	1	-1,32012	1	0,864229	1	0,8974	1
BSPRO	1	-0,19442	1	0,716006	1	0,646047	1
BTCIM	1	-2,02353	1	0,955552	1	1,049022	1
BURCE	0	-0,15789	1	0,667794	1	0,60601	1
BYRBY	0	3,858628	0	5,61E-06	0	-0,05435	0
BYSAN	0	2,058548	0	0,002319	0	-0,05338	0
CBSBO	0	1,956294	0	0,005828	0	-0,0291	0
CELHA	0	-0,13302	1	0,649587	1	0,658958	1
CEMTS	0	-0,94644	1	0,852431	1	0,318722	0
CEYLN	1	0,35186	0	0,606353	1	0,649458	1
CIMSA	1	-2,22447	1	0,974405	1	1,052311	1
CMENT	1	-0,68034	1	0,741614	1	1,027809	1

DARDL	0	0,614556	0	0,483129	0	-0,03682	0
DENCM	1	-0,44957	1	0,531681	1	0,937372	1
DERIM	0	1,756877	0	0,004367	0	-0,05278	0
DITAS	1	-0,10502	1	0,229188	0	0,80784	1
DMSAS	0	-0,8627	1	0,711552	1	-0,00777	0
DOBUR	1	-1,10309	1	0,828673	1	0,97657	1
DOKTS	0	0,0729	0	0,336536	0	0,276461	0
DUROF	0	1,259423	0	0,060396	0	-0,0318	0
DYOBY	0	1,12345	0	0,09027	0	-0,04406	0
ECILC	1	-0,35384	1	0,65138	1	0,96997	1
ECYAP	1	0,481568	0	0,143877	0	0,653313	1
EDIP	0	2,420785	0	0,001698	0	-0,05424	0
EBRA	1	-0,88089	1	0,500573	1	1,04425	1
EGEEN	1	-0,74763	1	0,858827	1	1,041754	1
EGGUB	1	0,306359	0	0,44432	0	0,811397	1
EGSER	0	1,824314	0	0,011186	0	-0,05041	0
EMKEL	0	0,91317	0	0,101124	0	-0,02051	0
EMNIS	0	1,702174	0	0,010253	0	-0,05222	0
EPLAS	0	0,600189	0	0,167196	0	0,083232	0
ERBOS	1	-0,72235	1	0,948789	1	0,88145	1
ERCYS	0	2,995428	0	0,000101	0	-0,05459	0
EREGL	0	1,6457	0	0,010779	0	0,121007	0
ERSU	0	2,43598	0	0,000472	0	-0,00554	0
ESEMS	0	0,222923	0	0,494055	0	0,144049	0
FENIS	1	-0,41958	1	0,735961	1	1,014539	1
FRIGO	0	2,035034	0	0,01036	0	-0,04934	0
FROTO	1	-2,04377	1	0,98292	1	1,047456	1
GEDIZ	0	0,853228	0	0,133178	0	-0,05244	0
GENTS	1	-1,93561	1	0,972362	1	0,965879	1
GOLTS	1	-1,1181	1	0,909273	1	0,779743	1
GOODY	0	1,271537	0	0,033311	0	0,052427	0
GORBN	0	0,963226	0	0,151611	0	-0,02889	0
GUBRF	1	-0,18956	1	0,758182	1	1,026331	1
GUMUS	0	0,1253	0	0,438178	0	0,037632	0
GUNEY	1	0,253511	0	0,237616	0	0,896618	1
HEKTS	1	-0,26437	1	0,760519	1	0,558209	1
HURGZ	1	-1,63193	1	0,760924	1	1,027317	1
HZNR	1	0,496254	0	0,387415	0	0,780803	1
IHEVA	0	-0,82496	1	0,933622	1	0,386733	0
ISAMB	0	2,100909	0	0,000986	0	-0,05224	0
IZMDC	0	-0,26021	1	0,358835	0	0,12802	0
KAPLM	0	-1,22613	1	0,512801	1	0,067355	0
KARSN	0	0,76284	0	0,144048	0	0,026036	0
KENT	0	1,61467	0	0,006639	0	-0,03782	0
KERVY	0	0,876164	0	0,378458	0	0,084653	0
KLBMO	0	0,015588	0	0,580482	1	0,44676	0
KNFRT	0	1,860881	0	0,022767	0	-0,05123	0
KOTKS	0	0,743397	0	0,25817	0	0,26229	0
LUKSK	0	1,074837	0	0,106533	0	0,041644	0
MAKTK	0	0,753286	0	0,093197	0	0,177344	0

Kontrol/Test Seti

Şirket Kodu	Başarı Durumu	Diskriminant Skoru	DA Tahmini	Lojistik Regresyon Olasılık Oranı	LR Tahmini	Yapay Sinir Ağı Çıktısı	YSA Tahmini
IZOCM	1	-1,46548	1	0,920052	1	1,036141	1
KLMSN	1	-0,76011	1	0,875634	1	0,929573	1
KORDS	1	0,215975	0	0,524553	1	0,037362	0
KUTPO	1	-1,16686	1	0,950352	1	0,920663	1
MARET	0	0,900532	0	0,005917	0	-0,02095	0
MERKO	0	2,227372	0	0,006009	0	-0,05475	0
MRDIN	1	-5,06334	1	0,999168	1	1,054621	1
NERGS	0	2,315215	0	0,001998	0	-0,04483	0
OLMKS	1	-0,83655	1	0,764042	1	0,971098	1
OYSAC	1	-3,40549	1	0,998469	1	1,05471	1
PETKM	1	-3,46857	1	0,992455	1	1,053814	1
PIMAS	0	0,640762	0	0,177693	0	0,185129	0
PINSU	0	1,548727	0	0,011407	0	-0,05362	0
POLYL	0	1,544401	0	0,007231	0	0,869799	1
PRTAS	0	-0,85824	1	0,942279	1	0,03672	0
RKSEV	0	1,113251	0	0,073925	0	0,102118	0
SABAH	1	1,07566	0	0,030786	0	-0,05027	0
SELGD	0	0,224848	0	0,49204	0	-0,0275	0
SERVE	1	-1,14651	1	0,951895	1	0,988363	1
SKTAS	0	1,363	0	0,017838	0	-0,04755	0
SONME	0	-1,29037	1	0,915848	1	0,137351	0
TATKS	1	-0,6095	1	0,925502	1	0,84296	1
TIRE	1	-0,29714	1	0,441012	0	0,706623	1
TUDDF	1	0,083212	0	0,318194	0	0,807239	1
TUMTK	0	2,686089	0	0,00054	0	-0,04138	0
UNTAR	0	-0,68096	1	0,964241	1	-0,05532	0
USAK	0	-0,3834	1	0,59375	1	0,341345	0
VAKKO	1	-2,89502	1	0,995028	1	1,054227	1
VESTL	1	-0,98723	1	0,878939	1	1,048233	1
VKING	0	1,303691	0	0,012437	0	-0,00878	0

**EK-6 BAŞARISIZLIKTAN 2 YIL ÖNCESİ İÇİN DİSKRİMİNANT ANALİZİ,
LOJİSTİK REGRESYON VE YAPAY SİNİR AĞLARI MODELLERİNİN
SONUÇLARI VE TAHMİNLERİ**

Kestirim/Eğitim Seti

Şirket Kodu	Başarı Durumu	Diskriminant Skoru	DA Tahmini	Lojistik Regresyon Olasılık Oranı	LR Tahmini	Yapay Sinir Ağı Çıktısı	YSA Tahmini
ADANA	1	-2,17218	1	0,978122	1	1,049267	1
ADEL	1	-0,80139	1	0,959116	1	1,049411	1
AFYON	1	1079,77	0	0,000001	0	-0,04806	0
AGIDA	1	-0,73628	1	0,829628	1	0,96766	1
AKALT	1	-0,33278	1	0,699976	1	0,532176	1
AKCNS	1	0,0693	0	0,470005	0	0,064081	0
AKIPD	1	-1,33987	1	0,799157	1	0,98937	1
AKSA	1	-2,34783	1	0,994817	1	1,054128	1
ALCAR	1	-1,45591	1	0,959116	1	1,053252	1
ALTIN	1	-0,32697	1	0,582542	1	0,933077	1
ALYAG	0	8,36944	0	3,33E-12	0	-0,05476	0
ANBRA	1	-0,14439	1	0,698033	1	0,891118	1
ARAT	0	4,467624	0	1,2E-06	0	-0,05452	0
ARCLK	1	-0,86756	1	0,778383	1	1,026519	1
ARDEM	1	-0,619	1	0,784407	1	1,031121	1
ARSAN	0	0,354034	0	0,293891	0	0,421879	0
ASLAN	0	-0,0088	1	0,264046	0	0,448425	0
ASUZU	0	2,743813	0	0,001546	0	-0,05227	0
ATEKS	1	-0,57502	1	0,824638	1	1,037571	1
BANVT	1	0,033263	0	0,549165	1	0,953871	1
BEKO	1	0,439277	0	0,450186	0	0,086104	0
BERDN	0	0,447578	0	0,314574	0	0,240449	0
BFREN	1	-1,95599	1	0,977893	1	1,053906	1
BOLUC	1	-2,78265	1	0,994339	1	0,60261	1
BOSSA	1	-1,10175	1	0,925907	1	1,053459	1
BRISA	1	-1,30277	1	0,941899	1	1,04031	1
BRMEN	0	-1,72431	1	0,973318	1	0,845313	1
BRSAN	1	0,650212	0	0,20226	0	0,900755	1
BSOKE	1	-3,43385	1	0,959784	1	0,621124	1
BSPRO	1	-0,31192	1	0,79833	1	0,774092	1
BTCIM	1	-1,56151	1	0,937228	1	1,050528	1
BURCE	0	-1,47049	1	0,967111	1	0,983856	1
BYRBY	0	3,789024	0	1,1E-05	0	-0,05419	0
BYSAN	0	1,959812	0	0,006852	0	-0,04107	0
CBSBO	0	4,133514	0	5,92E-05	0	-0,04522	0
CELHA	0	-0,1382	1	0,590906	1	0,888923	1
CEMTS	0	-1,24166	1	0,933983	1	0,981854	1
CEYLN	1	0,142824	0	0,60031	1	0,894261	1
CIMSA	1	-1,76567	1	0,966265	1	1,049447	1

CMENT	1	1,869922	0	0,019352	0	-0,04816	0
DARDL	0	0,630001	0	0,348663	0	-0,00229	0
DENCM	1	1,851533	0	0,001637	0	-0,02163	0
DERIM	0	-0,202	1	0,753958	1	0,435632	0
DITAS	1	-0,70763	1	0,482628	0	0,907895	1
DMSAS	0	-2,10395	1	0,958276	1	1,013928	1
DOBUR	1	0,377304	0	0,277542	0	0,099955	0
DOKTS	0	0,423217	0	0,243378	0	0,0111	0
DUROF	0	-0,87136	1	0,908798	1	1,027549	1
DYOBY	0	1,010275	0	0,099416	0	0,000809	0
ECILC	1	0,001465	0	0,274542	0	0,949619	1
ECYAP	1	0,812306	0	0,113221	0	0,151112	0
EDIP	0	2,490885	0	0,000548	0	-0,05344	0
EGBRA	1	0,661231	0	0,180681	0	0,014251	0
EGEEN	1	0,04526	0	0,636082	1	0,137506	0
EGGUB	1	0,075153	0	0,458791	0	0,93441	1
EGSER	0	3,291618	0	0,000358	0	-0,05305	0
EMKEL	0	0,281656	0	0,365416	0	0,319155	0
EMNIS	0	-1,61395	1	0,979687	1	1,054148	1
EPLAS	0	6,067631	0	6,53E-09	0	-0,05516	0
ERBOS	1	-0,48559	1	0,904262	1	1,04779	1
ERCYS	0	-1,23574	1	0,806027	1	0,222833	0
EREGL	0	2,17634	0	0,001012	0	-0,0532	0
ERSU	0	-0,3498	1	0,910773	1	0,046271	0
ESEMS	0	-0,55541	1	0,855029	1	0,981388	1
FENIS	1	-0,59485	1	0,770392	1	1,032476	1
FRIGO	0	1,96348	0	0,011392	0	-0,05196	0
FROTO	1	-2,62219	1	0,996325	1	0,238832	0
GEDIZ	0	2,857085	0	0,002253	0	-0,05539	0
GENTS	1	-2,44396	1	0,967509	1	1,052318	1
GOLTS	1	0,34952	0	0,309804	0	0,301598	0
GOODY	0	-0,24577	1	0,602748	1	0,935146	1
GORBN	0	0,771421	0	0,184388	0	0,07658	0
GUBRF	1	-0,21902	1	0,86732	1	0,152363	0
GUMUS	0	0,266605	0	0,193759	0	0,210226	0
GUNEY	1	0,104166	0	0,358417	0	0,602687	1
HEKTS	1	0,040717	0	0,585913	1	0,399982	0
HURGZ	1	-0,65448	1	0,767376	1	1,03689	1
HZNDR	1	-0,10541	1	0,675247	1	0,870268	1
IHEVA	0	-0,12061	1	0,55493	1	0,433636	0
ISAMB	0	-0,39064	1	0,4098	0	1,044382	1
IZMDC	0	-0,226	1	0,280618	0	0,056403	0
KAPLM	0	-1,98364	1	0,737999	1	0,031936	0
KARSN	0	1,463884	0	0,012678	0	-0,04231	0
KENT	0	0,571542	0	0,053547	0	0,090711	0
KERVY	0	0,281886	0	0,74219	1	0,535412	1
KLBM0	0	-0,11877	1	0,599735	1	0,892962	1
KNFRT	0	1,01148	0	0,098974	0	-0,0505	0
KOTKS	0	1,379678	0	0,061767	0	0,086323	0
LUKSK	0	-1,54815	1	0,979603	1	0,071323	0
MAKTK	0	-1,15043	1	0,827842	1	0,846643	1

Kontrol/Test Seti

Şirket Kodu	Başarı Durumu	Diskriminant Skoru	DA Tahmini	Lojistik Regresyon Olasılık Oranı	LR Tahmini	Yapay Sinir Ağı Çıktısı	YSA Tahmini
IZOCM	1	0,454147	0	0,120614	0	0,21716	0
KLMSN	1	-2,5165	1	0,996335	1	1,053371	1
KORDS	1	-0,82285	1	0,921542	1	1,045128	1
KUTPO	1	-0,5757	1	0,826364	1	1,037692	1
MARET	0	1,586305	0	0,000748	0	0,126044	0
MERKO	0	0,976372	0	0,118306	0	-0,05324	0
MRDIN	1	-5,66194	1	0,999968	1	1,051519	1
NERGS	0	2,509108	0	0,000539	0	-0,0394	0
OLMKS	1	-0,8336	1	0,721245	1	0,754795	1
OYSAC	1	-3,05397	1	0,997917	1	1,054351	1
PETKM	1	-3,79866	1	0,998298	1	1,05103	1
PIMAS	0	-0,0805	1	0,472342	0	0,999911	1
PINSU	0	1,86569	0	0,008255	0	-0,00299	0
POLYL	0	3,592536	0	5,53E-05	0	-0,04611	0
PRTAS	0	-0,43102	1	0,863764	1	-0,01106	0
RKSEV	0	1,173053	0	0,038576	0	0,6161	1
SABAH	1	1,993829	0	0,000908	0	-0,03023	0
SELGD	0	1,793401	0	0,019284	0	-0,04204	0
SERVE	1	0,127815	0	0,406454	0	0,459839	0
SKTAS	0	-0,06588	1	0,316187	0	0,141059	0
SONME	0	0,70352	0	0,144974	0	0,027957	0
TATKS	1	-0,32726	1	0,890795	1	0,81545	1
TIRE	1	-2,36635	1	0,938519	1	1,049846	1
TUDDF	1	0,026338	0	0,423777	0	0,888247	1
TUMTK	0	0,516218	0	0,53284	1	0,434797	0
UNTAR	0	-0,55053	1	0,927967	1	-0,05532	0
USAK	0	-0,17052	1	0,439497	0	0,128137	0
VAKKO	1	1,4744	0	0,064877	0	0,787399	1
VESTL	1	-0,81973	1	0,919417	1	1,0214	1
VKING	0	0,085385	0	0,469983	0	0,053121	0

**EK-7 BAŞARISIZLIKTAN 3 YIL ÖNCESİ İÇİN DİSKRİMİNANT ANALİZİ,
LOJİSTİK REGRESYON VE YAPAY SİNİR AĞLARI MODELLERİNİN
SONUÇLARI VE TAHMİNLERİ**

Kestirim/Eğitim Seti

Şirket Kodu	Başarı Durumu	Diskriminant Skoru	DA Tahmini	Lojistik Regresyon Olasılık Oranı	LR Tahmini	Yapay Sinir Ağı Çıktısı	YSA Tahmini
ADANA	1	-1,75522	1	0,89468	1	1,030574	1
ADEL	1	-0,74866	1	0,947354	1	1,002127	1
AFYON	1	178,8079	0	8,8E-273	0	-0,04149	0
AGIDA	1	-0,86186	1	0,836992	1	0,951715	1
AKALT	1	-0,35571	1	0,745268	1	0,43618	0
AKCNS	1	0,070013	0	0,390019	0	-0,04131	0
AKIPD	1	-0,79483	1	0,826467	1	0,983957	1
AKSA	1	-1,69738	1	0,975324	1	1,04637	1
ALCAR	1	-1,40776	1	0,940578	1	1,049896	1
ALTIN	1	-0,49468	1	0,7276	1	0,882656	1
ALYAG	0	8,240026	0	4,28E-12	0	-0,05509	0
ANBRA	1	-1,02877	1	0,955198	1	0,608238	1
ARAT	0	-0,49191	1	0,93192	1	0,176645	0
ARCLK	1	-0,94953	1	0,873701	1	0,941771	1
ARDEM	1	-0,5274	1	0,609279	1	1,001428	1
ARSAN	0	0,609047	0	0,215256	0	-0,05098	0
ASLAN	0	-0,54688	1	0,435035	0	1,03324	1
ASUZU	0	-0,77542	1	0,901148	1	0,921606	1
ATEKS	1	0,548016	0	0,378127	0	-0,029	0
BANVT	1	1,373906	0	0,072207	0	0,049959	0
BEKO	1	7,578585	0	6,79E-12	0	-0,03592	0
BERDN	0	0,465144	0	0,354717	0	0,164484	0
BFREN	1	-0,82207	1	0,800018	1	1,044582	1
BOLUC	1	-1,1452	1	0,764167	1	1,008844	1
BOSSA	1	-0,60944	1	0,861696	1	0,974964	1
BRISA	1	-1,18937	1	0,921445	1	0,099806	0
BRMEN	0	-10,5616	1	0,99826	1	-0,02391	0
BRSAN	1	0,392515	0	0,324217	0	0,277929	0
BSOKE	1	-2,24618	1	0,543413	1	0,561753	1
BSPRO	1	-0,04705	1	0,638246	1	0,6508	1
BTCIM	1	-0,84108	1	0,747508	1	0,96366	1
BURCE	0	-1,01601	1	0,919714	1	1,03191	1
BYRBY	0	-0,2475	1	0,826022	1	1,046143	1
BYSAN	0	2,976878	0	0,00052	0	-0,05524	0
CBSBO	0	0,787816	0	0,142021	0	0,091743	0
CELHA	0	-1,25673	1	0,937424	1	1,053091	1
CEMTS	0	-1,33975	1	0,943811	1	1,05092	1
CEYLN	1	1,75674	0	0,051586	0	-0,03715	0
CIMSA	1	-1,53885	1	0,907467	1	0,978552	1

CMENT	1	0,896281	0	0,109935	0	-0,04624	0
DARDL	0	0,528559	0	0,344995	0	-0,02391	0
DENCM	1	2,279193	0	0,00012	0	0,224	0
DERIM	0	1,216724	0	0,0836	0	-0,03747	0
DITAS	1	-1,11782	1	0,681585	1	0,621144	1
DMSAS	0	-0,68561	1	0,741148	1	0,04248	0
DOBUR	1	-0,85392	1	0,845518	1	1,05067	1
DOKTS	0	1,290313	0	0,024185	0	-0,05337	0
DUROF	0	1,175761	0	0,040897	0	0,345286	0
DYOBY	0	0,587391	0	0,160459	0	0,903676	1
ECILC	1	-1,01669	1	0,778082	1	1,038606	1
ECYAP	1	-0,02183	1	0,395061	0	0,221216	0
EDIP	0	0,334324	0	0,189003	0	-0,04172	0
EGBRA	1	-0,95861	1	0,894011	1	0,000117	0
EGEEN	1	-0,97077	1	0,933297	1	1,034146	1
EGGUB	1	0,750795	0	0,318437	0	0,012503	0
EGSER	0	7,338509	0	3,05E-11	0	-0,04996	0
EMNIS	0	-1,51003	1	0,877332	1	1,05458	1
EPLAS	0	1,368535	0	0,010143	0	-0,02349	0
ERBOS	1	0,18987	0	0,650037	1	0,019461	0
ERCYS	0	-5,32579	1	0,999768	1	1,054881	1
EREGL	0	-0,03836	1	0,124187	0	-0,05055	0
ERSU	0	-0,59588	1	0,896184	1	1,047266	1
ESEMS	0	-0,54128	1	0,856169	1	1,019294	1
FENIS	1	-0,2918	1	0,660326	1	1,031813	1
FRIGO	0	1,465718	0	0,032552	0	-0,03307	0
FROTO	1	-2,76093	1	0,997039	1	0,231622	0
GEDIZ	0	-2,30638	1	0,89277	1	1,009202	1
GENTS	1	-2,9345	1	0,994487	1	1,032257	1
GOLTS	1	-0,65134	1	0,717755	1	0,277965	0
GOODY	0	-1,49229	1	0,969382	1	1,018146	1
GORBN	0	0,148956	0	0,563273	1	1,014614	1
GUBRF	1	-0,27633	1	0,850389	1	0,143999	0
GUNEY	1	-2,14942	1	0,973399	1	1,054055	1
HEKTS	1	-0,21077	1	0,65216	1	0,090698	0
HURGZ	1	-2,36568	1	0,981694	1	1,053113	1
HZNDR	1	0,239704	0	0,613501	1	0,074918	0
IHEVA	0	0,053283	0	0,675127	1	0,146334	0
ISAMB	0	-0,26371	1	0,104254	0	0,771198	1
IZMDC	0	-0,98631	1	0,468351	0	0,380974	0
KAPLM	0	-1,90896	1	0,964803	1	1,052854	1
KARSN	0	-0,4745	1	0,794473	1	0,995828	1
KENT	0	-0,15484	1	0,147235	0	-0,00276	0
KERTV	0	0,644667	0	0,34154	0	0,159613	0
KLBM0	0	-0,6117	1	0,812308	1	1,007267	1
KNFRT	0	1,949097	0	0,00062	0	-0,02991	0
KOTKS	0	0,888179	0	0,174862	0	0,158205	0
LUKSK	0	-1,68254	1	0,98038	1	1,046085	1
MAKTK	0	-0,89141	1	0,859389	1	0,79856	1

Kontrol/Test Seti

Şirket Kodu	Başarı Durumu	Diskriminant Skoru	DA Tahmini	Lojistik Regresyon Olasılık Oranı	LR Tahmini	Yapay Sinir Ağı Çıktısı	YSA Tahmini
IZOCM	1	-0,68886	1	0,634343	1	0,95107	1
KLMSN	1	-2,68671	1	0,989602	1	1,054418	1
KORDS	1	-1,72083	1	0,987408	1	1,05344	1
KUTPO	1	0,455616	0	0,317906	0	0,06102	0
MARET	0	19,12258	0	1,27E-29	0	-0,03756	0
MERKO	0	0,865775	0	0,140221	0	-0,04646	0
MRDIN	1	-4,11866	1	0,999231	1	1,053633	1
NERGS	0	0,407166	0	0,486762	0	-0,04621	0
OLMKS	1	-0,68462	1	0,699804	1	0,992303	1
OYSAC	1	-2,68227	1	0,990662	1	1,054434	1
PETKM	1	-4,49101	1	0,999634	1	1,05361	1
PIMAS	0	0,503165	0	0,107962	0	0,92562	1
PINSU	0	2,061064	0	0,00333	0	0,038343	0
POLYL	0	1,65342	0	0,012198	0	-0,03996	0
PRTAS	0	-0,5081	1	0,872718	1	0,815503	1
RKSEV	0	0,358255	0	0,326706	0	0,652359	1
SABAH	1	1,411214	0	0,007376	0	-0,02735	0
SELGD	0	-0,4	1	0,787409	1	0,084611	0
SERVE	1	-1,23977	1	0,948101	1	1,009171	1
SKTAS	0	-0,12391	1	0,44432	0	0,208161	0
SONME	0	0,178841	0	0,630258	1	0,275952	0
TATKS	1	0,329747	0	0,585811	1	0,383407	0
TIRE	1	-2,15116	1	0,946851	1	1,051074	1
TUDDF	1	0,78358	0	0,07871	0	0,808068	1
TUMTK	0	-0,19669	1	0,82224	1	0,482808	0
UNTAR	0	-0,63089	1	0,959406	1	-0,05526	0
USAK	0	-0,49597	1	0,708418	1	0,717917	1
VAKKO	1	-1,36362	1	0,948244	1	1,016876	1
VESTL	1	-1,14206	1	0,962704	1	0,87128	1
VKING	0	-1,78825	1	0,978503	1	1,053636	1

**EK-8 BAŞARISIZLIKTAN 4 YIL ÖNCESİ İÇİN DİSKRİMİNANT ANALİZİ,
LOJİSTİK REGRESYON VE YAPAY SİNİR AĞLARI MODELLERİNİN
SONUÇLARI VE TAHMİNLERİ**

Kestirim/Eğitim Seti

Şirket Kodu	Başarı Durumu	Diskriminant Skoru	DA Tahmini	Lojistik Regresyon Olasılık Oranı	LR Tahmini	Yapay Sinir Ağı Çıktısı	YSA Tahmini
ADANA	1	-3,35957	1	0,988157	1	1,043065	1
ADEL	1	-2,24174	1	0,99524	1	1,041934	1
AFYON	1	4,002899	0	1,05E-06	0	0,500303	1
AGIDA	1	-0,00567	1	0,423715	0	0,854459	1
AKALT	1	-1,13411	1	0,921147	1	0,722105	1
AKCNS	1	-1,23567	1	0,887269	1	1,022428	1
AKIPD	1	-2,04694	1	0,972241	1	1,048523	1
AKSA	1	-2,4812	1	0,994041	1	1,053724	1
ALCAR	1	-2,22145	1	0,987554	1	1,054268	1
ALTIN	1	-0,38462	1	0,764816	1	0,981996	1
ANBRA	1	-2,58638	1	0,977921	1	0,076429	0
ARAT	0	0,641074	0	0,414778	0	-0,03663	0
ARCLK	1	-1,64295	1	0,95016	1	1,052283	1
ARDEM	1	-2,52171	1	0,992738	1	1,05341	1
ARSAN	0	0,309607	0	0,364106	0	-0,03768	0
ASLAN	0	1,225983	0	0,015125	0	0,053154	0
ASUZU	0	-3,33194	1	0,998974	1	1,052557	1
ATEKS	1	0,11785	0	0,567021	1	0,855665	1
BANVT	1	-0,85892	1	0,91663	1	1,048697	1
BEKO	1	-0,439	1	0,850324	1	0,322362	0
BERDN	0	1,169099	0	0,128244	0	0,070376	0
BFREN	1	0,072992	0	0,464267	0	0,972741	1
BOLUC	1	-1,02217	1	0,841983	1	0,916389	1
BOSSA	1	-1,27138	1	0,957692	1	1,048466	1
BRISA	1	-1,48643	1	0,95791	1	1,052509	1
BRMEN	0	0,359004	0	0,434565	0	0,844032	1
BRSAN	1	0,306676	0	0,382695	0	0,61864	1
BSOKE	1	-1,14879	1	0,749668	1	0,1949	0
BSPRO	1	0,122897	0	0,585091	1	0,217745	0
BTCIM	1	0,339606	0	0,362446	0	0,757568	1
BURCE	0	-1,35862	1	0,958359	1	1,042075	1
BYRBY	0	-0,20376	1	0,8484	1	0,217826	0
BYSAN	0	4,551185	0	1,59E-06	0	-0,05508	0
CBSBO	0	-0,11293	1	0,759644	1	0,379384	0
CELHA	0	-1,3818	1	0,93952	1	1,052685	1
CEMTS	0	-1,13735	1	0,894304	1	0,891826	1
CEYLN	1	-0,4666	1	0,907165	1	0,921274	1
CIMSA	1	-1,46458	1	0,87845	1	0,605312	1
CMENT	1	1,357887	0	0,048948	0	-0,0359	0

DARDL	0	0,632177	0	0,260987	0	0,172508	0
DENCM	1	0,23579	0	0,246122	0	0,779888	1
DERIM	0	2,218266	0	0,003078	0	-0,04714	0
DITAS	1	-0,84519	1	0,756002	1	0,239909	0
DMSAS	0	0,282668	0	0,286815	0	0,8176	1
DOBUR	1	-0,48664	1	0,741092	1	1,037984	1
DOKTS	0	-0,51733	1	0,767835	1	0,97706	1
DUROF	0	2,586612	0	0,003653	0	-0,05247	0
DYOBY	0	2,758644	0	5,51E-05	0	0,56244	1
ECILC	1	-0,63607	1	0,650612	1	0,91382	1
ECYAP	1	-0,1197	1	0,551042	1	0,285703	0
EDIP	0	-0,64017	1	0,814322	1	-0,00163	0
EGBRA	1	-3,43828	1	0,99873	1	-0,03347	0
EGEEN	1	-1,54037	1	0,980436	1	1,048713	1
EGGUB	1	-1,04135	1	0,855181	1	1,054298	1
EGSER	0	0,451637	0	0,14946	0	0,710824	1
EPLAS	0	-0,00672	1	0,42949	0	0,607733	1
ERBOS	1	-1,1385	1	0,966278	1	1,009588	1
ERCYS	0	-3,99502	1	0,999033	1	1,054766	1
EREGL	0	1,623094	0	0,002312	0	-0,04746	0
ERSU	0	-0,57135	1	0,875064	1	1,03288	1
ESEMS	0	-1,42364	1	0,969096	1	1,051533	1
FENIS	1	0,346571	0	0,303886	0	1,030284	1
FRIGO	0	1,516617	0	0,046674	0	-0,03153	0
FROTO	1	-1,85871	1	0,987342	1	0,520058	1
GEDIZ	0	-1,44882	1	0,807082	1	0,945591	1
GENTS	1	-4,61375	1	0,999842	1	0,434609	0
GOLTS	1	-0,99425	1	0,874493	1	0,03699	0
GOODY	0	-1,55173	1	0,971868	1	1,036028	1
GORBN	0	-0,04174	1	0,692678	1	1,030736	1
GUBRF	1	-0,41342	1	0,86564	1	0,962743	1
GUNEY	1	-1,98276	1	0,969626	1	0,077657	0
HEKTS	1	2,507743	0	0,010295	0	-0,05337	0
HURGZ	1	-3,74013	1	0,998625	1	1,054211	1
HZNDR	1	-0,46321	1	0,841737	1	0,863442	1
IHEVA	0	-0,2256	1	0,769447	1	-0,02523	0
ISAMB	0	-1,35148	1	0,91808	1	1,014748	1
IZMDC	0	-0,03232	1	0,362418	0	0,671765	1
KAPLM	0	-1,03526	1	0,878826	1	1,053724	1
KENT	0	0,720095	0	0,083838	0	0,833694	1
KERVT	0	0,642194	0	0,315486	0	0,184667	0
KLBM0	0	-1,09261	1	0,918028	1	1,048393	1
KNFRT	0	1,445414	0	0,01482	0	0,114546	0
KOTKS	0	0,808106	0	0,177051	0	0,990734	1
LUKSK	0	-0,70511	1	0,889307	1	0,964186	1
MAKTK	0	-1,10016	1	0,932856	1	0,96433	1

Kontrol/Test Seti

Şirket Kodu	Başarı Durumu	Diskriminant Skoru	DA Tahmini	Lojistik Regresyon Olasılık Oranı	LR Tahmini	Yapay Sinir Ağı Çıktısı	YSA Tahmini
IZOCM	1	-1,10613	1	0,749976	1	1,037219	1
KLMSN	1	-3,27477	1	0,997898	1	1,054643	1
KORDS	1	-1,78945	1	0,985267	1	1,040646	1
KUTPO	1	1,931234	0	0,016347	0	-0,05243	0
MARET	0	3,737565	0	5,47E-06	0	-0,05139	0
MERKO	0	1,074539	0	0,078472	0	-0,05201	0
MRDIN	1	-4,67088	1	0,999751	1	1,04669	1
NERGS	0	0,286337	0	0,504339	1	0,013393	0
OLMKS	1	0,501238	0	0,295794	0	0,040879	0
OYSAC	1	-3,30802	1	0,998727	1	1,054001	1
PETKM	1	-1,05515	1	0,851525	1	1,051749	1
PIMAS	0	1,122829	0	0,050163	0	0,013959	0
PINSU	0	11,58658	0	4,75E-16	0	-0,0554	0
POLYL	0	1,693149	0	0,017236	0	0,061984	0
PRTAS	0	-0,03137	1	0,562144	1	1,006232	1
RKSEV	0	-0,79725	1	0,867451	1	0,874458	1
SABAH	1	-0,73887	1	0,584781	1	0,935762	1
SELGD	0	0,711259	0	0,409333	0	-0,01372	0
SERVE	1	0,188156	0	0,558305	1	0,604479	1
SKTAS	0	0,268093	0	0,259606	0	1,004122	1
SONME	0	-0,78822	1	0,852015	1	1,024588	1
TATKS	1	-0,41604	1	0,829711	1	0,730761	1
TIRE	1	-0,92844	1	0,779402	1	0,947904	1
TUDDF	1	1,737861	0	0,000642	0	0,494261	0
TUMTK	0	1,450861	0	0,033361	0	-0,0268	0
UNTAR	0	-1,0106	1	0,97303	1	-0,04274	0
USAK	0	-1,32477	1	0,923333	1	0,996977	1
VAKKO	1	-1,94965	1	0,975762	1	1,051535	1
VESTL	1	-0,68043	1	0,912703	1	0,890988	1
VKING	0	-1,19201	1	0,975729	1	1,010352	1

**EK-9 BAŞARISIZLIKTAN 5 YIL ÖNCESİ İÇİN DİSKRİMİNANT ANALİZİ,
LOJİSTİK REGRESYON VE YAPAY SİNİR AĞLARI MODELLERİNİN
SONUÇLARI VE TAHMİNLERİ**

Kestirim/Eğitim Seti

Şirket Kodu	Başarı Durumu	Diskriminant Skoru	DA Tahmini	Lojistik Regresyon Olasılık Oranı	LR Tahmini	Yapay Sinir Ağı Çıktısı	YSA Tahmini
ADANA	1	-2,45026	1	0,916135	1	1,046303	1
ADEL	1	-2,63811	1	0,997279	1	1,053373	1
AFYON	1	-1,53614	1	0,970863	1	1,054295	1
AGIDA	1	-0,21208	1	0,682318	1	0,843933	1
AKALT	1	-0,79178	1	0,847226	1	1,046046	1
AKCNS	1	-2,0094	1	0,951786	1	1,052768	1
AKIPD	1	-1,6544	1	0,950746	1	1,037765	1
AKSA	1	-2,56247	1	0,98364	1	1,051215	1
ALCAR	1	-2,55981	1	0,992784	1	1,053138	1
ALTIN	1	-1,38105	1	0,941962	1	0,865548	1
ANBRA	1	-3,1694	1	0,971306	1	1,053577	1
ARAT	0	0,230579	0	0,666037	1	-0,04737	0
ARCLK	1	-1,80978	1	0,922387	1	1,050696	1
ARDEM	1	-2,58291	1	0,995929	1	1,05341	1
ARSAN	0	-0,14183	1	0,527988	1	0,004279	0
ASLAN	0	2,267979	0	0,001077	0	-0,0499	0
ASUZU	0	-2,32824	1	0,996221	1	1,050568	1
ATEKS	1	-0,01781	1	0,576747	1	0,863692	1
BANVT	1	0,885545	0	0,190642	0	0,104661	0
BEKO	1	-1,68039	1	0,989034	1	1,04318	1
BERDN	0	1,824758	0	0,023342	0	-0,03219	0
BFREN	1	1,306078	0	0,026945	0	-0,01219	0
BOLUC	1	-1,03371	1	0,768913	1	0,890842	1
BOSSA	1	-0,94554	1	0,914271	1	1,047455	1
BRISA	1	-1,56465	1	0,96071	1	1,050678	1
BRSAN	1	0,01316	0	0,518131	1	1,036003	1
BSOKE	1	1,191132	0	0,05798	0	0,611918	1
BSPRO	1	-0,28507	1	0,686888	1	0,90229	1
BTCIM	1	-0,43349	1	0,540534	1	1,037931	1
BURCE	0	-1,3944	1	0,952518	1	0,930397	1
CBSBO	0	-0,3002	1	0,833985	1	0,56243	1
CELHA	0	-0,71722	1	0,816981	1	1,048284	1
CEMTS	0	-1,87159	1	0,979269	1	1,054026	1
CEYLN	1	0,302671	0	0,48381	0	0,03064	0
CIMSA	1	-1,77953	1	0,947187	1	0,956764	1
CMENT	1	0,531218	0	0,166764	0	0,086729	0
DARDL	0	-0,40813	1	0,805706	1	0,979256	1
DENCM	1	3,265923	0	2,95E-05	0	-0,03868	0
DERIM	0	0,402438	0	0,619499	1	0,835094	1

DITAS	1	-2,3322	1	0,993011	1	1,054326	1
DMSAS	0	1,37206	0	0,083517	0	-0,0408	0
DOKTS	0	-1,6794	1	0,962415	1	0,940571	1
DUROF	0	0,863005	0	0,116764	0	0,054222	0
DYOBY	0	-0,94447	1	0,9014	1	1,053159	1
ECILC	1	0,80466	0	0,062833	0	0,79275	1
ECYAP	1	-0,65679	1	0,785996	1	1,037819	1
EDIP	0	-1,12626	1	0,952327	1	1,034697	1
EGBRA	1	-3,80355	1	0,998792	1	0,117912	0
EGEEN	1	-1,07708	1	0,946592	1	0,964352	1
EGGUB	1	-1,67269	1	0,978618	1	1,05389	1
EGSER	0	-0,33365	1	0,384193	0	0,990861	1
EPLAS	0	-2,43079	1	0,985812	1	1,035324	1
ERBOS	1	-0,82395	1	0,946974	1	0,992698	1
ERCYS	0	-1,54239	1	0,947938	1	1,036133	1
EREGL	0	0,84394	0	0,0613	0	-0,04765	0
ESEMS	0	-1,36044	1	0,978445	1	1,035377	1
FENIS	1	0,769542	0	0,125357	0	0,110078	0
FRIGO	0	0,703926	0	0,189198	0	-0,02225	0
FROTO	1	-1,09983	1	0,933072	1	1,017123	1
GEDIZ	0	-0,9583	1	0,725729	1	0,914034	1
GENTS	1	-4,206	1	0,999684	1	1,053671	1
GOLTS	1	-2,12311	1	0,972749	1	0,962464	1
GOODY	0	-1,23356	1	0,953529	1	1,019323	1
GORBN	0	0,369343	0	0,428057	0	0,832465	1
GUBRF	1	-0,28543	1	0,834944	1	0,957932	1
GUNEY	1	-1,60673	1	0,954336	1	1,053261	1
HEKTS	1	0,889488	0	0,070178	0	0,008003	0
HURGZ	1	-0,77451	1	0,649149	1	1,042048	1
HZNDR	1	-1,52715	1	0,98012	1	1,009213	1
IHEVA	0	0,895341	0	0,266077	0	0,519845	1
ISAMB	0	1,688519	0	0,007354	0	-0,04832	0
IZMDC	0	0,120382	0	0,367883	0	0,214333	0
KAPLM	0	0,202561	0	0,293907	0	0,269036	0
KENT	0	0,037252	0	0,550964	1	0,627473	1
KERVY	0	-0,13591	1	0,762316	1	0,87897	1
KLBM0	0	-1,03506	1	0,911895	1	1,047282	1
KOTKS	0	1,170933	0	0,060248	0	0,313764	0
LUKSK	0	-1,67314	1	0,992491	1	1,011265	1
MAKTK	0	-1,32117	1	0,946384	1	0,602996	1

Kontrol/Test Seti

Şirket Kodu	Başarı Durumu	Diskriminant Skoru	DA Tahmini	Lojistik Regresyon Olasılık Oranı	LR Tahmini	Yapay Sinir Ağı Çıktısı	YSA Tahmini
IZOCM	1	-1,78498	1	0,943219	1	1,053623	1
KLMSN	1	-0,0189	1	0,73375	1	0,80603	1
KORDS	1	-1,8576	1	0,985954	1	1,046219	1
KUTPO	1	0,56008	0	0,323012	0	0,214326	0
MARET	0	4,260705	0	1,41E-07	0	-0,04661	0
MERKO	0	-0,09958	1	0,512365	1	-0,03899	0
MRDIN	1	-3,39398	1	0,997219	1	1,048915	1
NERGS	0	1,243217	0	0,054094	0	0,316348	0
OLMKS	1	1,963636	0	0,01221	0	-0,05346	0
OYSAC	1	-3,73247	1	0,998494	1	1,054708	1
PETKM	1	6,353758	0	5,71E-08	0	-0,05471	0
PIMAS	0	2,400279	0	0,001487	0	0,014401	0
PINSU	0	7,232863	0	4,17E-10	0	-0,05509	0
POLYL	0	4,385146	0	2,59E-06	0	-0,05508	0
PRTAS	0	0,430276	0	0,263506	0	1,039868	1
RKSEV	0	0,714359	0	0,125705	0	0,562765	1
SABAH	1	5,989247	0	3,01E-10	0	-0,03247	0
SELGD	0	0,495971	0	0,544515	1	-0,02688	0
SERVE	1	-0,06846	1	0,704156	1	-0,01678	0
SKTAS	0	1,611442	0	0,009017	0	-0,02025	0
SONME	0	0,974071	0	0,081251	0	-0,04736	0
TATKS	1	-0,19071	1	0,820796	1	0,941631	1
TIRE	1	-0,76016	1	0,56414	1	0,726188	1
TUDDF	1	-0,96721	1	0,877892	1	1,030911	1
TUMTK	0	2,05536	0	0,006694	0	-0,05155	0
UNTAR	0	-0,60767	1	0,927026	1	0,410159	0
USAK	0	-3,61876	1	0,999002	1	1,049465	1
VAKKO	1	-2,19621	1	0,991132	1	1,052718	1
VESTL	1	-0,53076	1	0,864267	1	1,009456	1
VKING	0	-1,25975	1	0,9425	1	1,053164	1

ÖZGEÇMİŞ

1974 yılında Kayseri’de doğdu. İlk, orta ve lise tahsilini Kayseri’de tamamladı. İki yıl Uludağ Üniversitesi Bursa Meslek Yüksek Okulu’nda Bilgisayar Programcılığı bölümüne devam ettikten sonra, 1999 yılında Erciyes Üniversitesi İktisadi ve İdari Bilimler Fakültesi İşletme bölümünden mezun oldu. Aynı yıl bu fakültede Araştırma Görevlisi olarak akademik hayatına başladı. 2001 yılında “Kayseri’de Faaliyet Gösteren Seçilmiş Üç Tekstil Firmasının Finansal Analizi” isimli tezini sunarak, Erciyes Üniversitesi Sosyal Bilimler Enstitüsü İşletme Anabilim Dalı Yüksek Lisans programından mezun oldu. 2007 yılında “Finansal Başarısızlık Tahmininde Geleneksel İstatistiksel Yöntemlerle Yapay Sinir Ağlarının Karşılaştırılması ve Sanayi İşletmeleri Üzerinde Uygulama” isimli doktora tezini sundu. Evli ve iki çocuk babası olan Talip TORUN, İngilizce bilmektedir.

İletişim Adresi: Erciyes Üniversitesi İ.İ.B.F.

İşletme Bölümü 38039 Melikgazi/KAYSERİ

Telefon: (0 352) 437 49 31 Dahili: 30 107

Fax: (0 352) 437 52 39

E-posta: torunt@erciyes.edu.tr

