

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

**FİNANSAL BAŞARISIZLIĞIN ÖNGÖRÜLMESİNDE
YAPAY SİNİR AĞI KULLANIMI
VE AMPİRİK BİR ÇALIŞMA**

(Doktora Tezi)

Danışman : Prof.Dr. Hüseyin ERGİN

Birol YILDIZ

T 89173

KÜTAHYA, 1999

**T.C. YÜKSEKÖĞRETİM KURULU
DOKÜMANTASYON MERKEZİ**

Birol YILDIZ'ın hazırladığı "**Finansal Başarısızlığın Öngörülmesinde Yapay Sinir Ağı Kullanımı ve Ampirik Bir Çalışma**" adlı Doktora Tez Çalışması jüri tarafından lisansüstü yönetmeliğinin ilgili maddesine göre değerlendirilip, kabul edilmiştir.

Tarih: 23 Mart 1999

Tez Jürisi

Prof.Dr.Hüseyin ERGİN (Danışman)



Doç.Dr.Münevver YILANCI



Doç.Dr.Şerafettin SEVİM



Prof.Dr.Ahmet KARAASLAN
Sosyal Bilimler Enstitüsü Müdürü



ÖZGEÇMİŞ

Eskişehir 1971 doğumluyum. İlk, orta ve lise eğitimimi Eskişehir’de tamamladım. Lisans öğrenimimi Dumlupınar Üniversitesi İktisadi ve İdari Bilimler Fakültesi İşletme Bölümü’nde, yüksek lisans eğitimimi Dumlupınar Üniversitesi Sosyal Bilimler Enstitüsü Muhasebe-Finans anabilim bilim dalında “Kalite Maliyetlerinin Raporlanması” adlı tezle yaptım.

1993 yılında Dumlupınar Üniversitesi İktisadi ve İdari Bilimler Fakültesi İşletme Bölümü Muhasebe Finans anabilim dalında araştırma görevlisi olarak göreve başladım. 1998 yılı Eylül ayından itibaren Osmangazi Üniversitesi İktisadi ve İdari Bilimler Fakültesi İşletme Bölümü Muhasebe-Finans anabilim dalında araştırma görevlisi olarak görev yapmaktayım. İngilizce ve bilgisayar biliyorum. Evliyim.

ÖZET

Finansal başarısızlığın öngörülmesi tüm bilgi kullanıcılarını yakından ilgilendiren bir konudur. Finansal başarısızlığı öngörmek amacıyla finansal oranları değişken olarak kullanan çok sayıda model içinde, çok değişkenli ayırma analizi en yaygın kullanılan istatistik tekniktir. Bununla beraber ayırma analizinin, ancak dayandığı varsayımlar gerçekleştiğinde doğru sonuçlar üreteceği söylenebilir. Yapay sinir ağı sahip olduğu avantajlar nedeniyle, finansal başarısızlığın öngörülmesinde kullanılabilir alternatif bir teknoloji durumundadır. Bu çalışmada; finansal başarısızlığı öngörme konusunda ayırma analizi tekniği ve yapay sinir ağı teknolojisi karşılaştırılmış, yapay sinir ağının finansal başarısızlığı öngörmede daha başarılı olduğu görülmüştür.

ANAHTAR KELİMELER:

1. Finansal başarısızlık
2. Yapay sinir ağları

ABSTRACT

Creditors, invertors, stockholders and managers interest in using financial ratios to predict financial failure. Multivarite discriminant analysis is one of the most of popular statistical technique used to predict financial failure. But multivarite discriminant analysis has some restrictive assumptions and it may be a valid technique only under these assumtions. Artificial Neural Networks is an alternative technology to predict financial failure. Comparision of the nural network and discriminant analysis in context of predict financial failure, neural networks provided better results then multivarite discriminant analysis.

KEYWORDS :

1. Financial failure
2. Artificial Neural Networks

İÇİNDEKİLER

| | |
|-------------------|------|
| Özgeçmiş | i |
| Özet | ii |
| Abstract | iii |
| Tablolar | viii |
| Şekiller | ix |
| Kısaltmalar | x |
| | |
| Giriş | 1 |

BİRİNCİ BÖLÜM

ÇALIŞMANIN AMACI, KAPSAMI ve YÖNTEMİ

| | |
|---------------------------------|---|
| 1.1. ARAŞTIRMANIN AMACI | 4 |
| 1.2. ARAŞTIRMANIN KAPSAMI | 6 |
| 1.3. ARAŞTIRMANIN YÖNTEMİ | 7 |

İKİNCİ BÖLÜM

FİNANSAL BAŞARISIZLIK

| | |
|--|----|
| 2.1. FİNANSAL BAŞARISIZLIK KAVRAMI | 9 |
| 2.2. FİNANSAL BAŞARISIZLIĞIN NEDENLERİ VE ETKİLERİ | 15 |
| 2.2.1. Finansal Başarısızlığın Nedenleri | 15 |
| 2.2.2. Finansal Başarısızlığın Etkileri | 19 |
| 2.3. FİNANSAL BAŞARISIZLIĞIN ÖNGÖRÜLMESİNİN ÖNEMİ | 19 |

| | |
|--|----|
| 2.3.1. Yatırımcılar Açısından Önemi | 20 |
| 2.3.2. Kredi Verenler Açısından Önemi | 21 |
| 2.3.3. Devlet Açısından Önemi | 21 |
| 2.3.4. Düzenleyici Kuruluşlar Açısından Önemi..... | 22 |
| 2.3.5. Bağımsız Denetçiler Açısından Önemi | 23 |
| 2.3.6. İşletme Yöneticileri Açısından Önemi | 23 |

ÜÇÜNCÜ BÖLÜM

FİNANSAL BAŞARISIZLIĞIN ÖNGÖRÜLMESİ

| | |
|--|----|
| 3.1. FİNANSAL BAŞARISIZLIĞIN ÖNGÖRÜLMESİNDE | |
| KULLANILAN MODELLER..... | 26 |
| 3.1.1. Matematiksel – İstatistiksel Modeller | 27 |
| 3.1.1.1. Tek Değişkenli Modeller..... | 28 |
| 3.1.1.2. Çok Değişkenli Modeller | 32 |
| 3.1.1.3. Felaket Teorisine Dayanan Modeller | 56 |
| 3.1.1.4. Parametrik Olmayan Modeller | 60 |
| 3.1.2. İnsan Yargısına Dayalı Modeller | 62 |
| 3.1.3. Yapay Zeka Teknolojisine Dayalı Modeller | 67 |
| 3.1.3.1. Uzman Sistem Kullanan Çalışmalar | 68 |
| 3.1.3.2. Yapay Sinir Ağı Teknolojisini Kullanan Modeller | 71 |
| 3.2. FİNANSAL BAŞARISIZLIĞIN ÖNGÖRÜLMESİNDE | |
| KULLANILAN MATEMATİKSEL - İSTATİSTİKSEL | |
| MODELLERİN DEĞERLENDİRİLMESİ..... | 71 |
| 3.2.1. Finansal Oranların Çok Değişkenli Normal Dağılım Özelliğini | |
| Göstermemesi Sorunu | 73 |
| 3.2.2. Değişken Olarak Kullanılan Finansal Oranların | |
| Çoklu Korelasyon Göstermesi Sorunu..... | 75 |
| 3.2.3. Değişkenlerin Dönemsel Olarak İstikrarsızlığı Sorunu | 76 |
| 3.2.4. Örneklemin Evreni Temsil Etmemesi Sorunu | 78 |

| | |
|---|----|
| 3.2.5. Örneklem Birimlerinin Eşleştirilmesi Sorunu..... | 79 |
| 3.2.6. Grupların Sapma Matrislerinin Eşit Olmaması Sorunu | 80 |
| 3.2.7. Modelin Büyüklüğü Sorunu | 80 |
| 3.2.8. Bağımlı Değişkeni Oluşturan Grupların Tanımlanması Sorunu..... | 81 |
| 3.2.9. Önsel Olasılık ve Yanlış Sınıflandırma Maliyetinin Belirlenememesi Sorunu | 82 |
| 3.2.10. Geçerlilik Sorunu | 83 |

DÖRDÜNCÜ BÖLÜM

YAPAY SİNİR AĞI TEKNOLOJİSİ VE FİNANSAL BAŞARISIZLIĞIN ÖNGÖRÜLMESİNDE KULLANIMI

| | |
|---|-----|
| 4.1. YAPAY SİNİR AĞI..... | 86 |
| 4.2. YAPAY SİNİR AĞI MODELİ..... | 90 |
| 4.2.1. Yapay Sinir Ağının Bileşenleri | 90 |
| 4.2.1.1. Neuron..... | 91 |
| 4.2.1.2. Bağlantılar | 91 |
| 4.2.1.3. Ağırlıklar | 93 |
| 4.2.2. Yapay Sinir Ağının İşleyişi | 93 |
| 4.2.2.1. Toplam Fonksiyonu..... | 94 |
| 4.2.2.2. Geçiş Fonksiyonu..... | 95 |
| 4.2.2.3. Yapay Sinir Ağında Öğrenme ve Öğrenme Algoritmaları..... | 96 |
| 4.3. YAPAY SİNİR AĞI MİMARİLERİ | 107 |
| 4.3.1. İleri Beslemeli Ağlar | 107 |
| 4.3.2. Geri Beslemeli Ağlar..... | 108 |
| 4.3.3. Hücresel Bağlantılı Ağlar..... | 108 |
| 4.4. YAPAY SİNİR AĞI GELİŞTİRME VE EĞİTME | 109 |
| 4.4.1. Yapay Sinir Ağının Geliştirilmesi Aşamaları | 110 |
| 4.4.1.1. Mimarinin Seçilmesi | 110 |
| 4.4.1.2. Neuronun Karakteristik Özellikleri..... | 112 |

| | | |
|----------|--|-----|
| 4.4.1.3. | Öğrenme Algoritmasının Seçimi..... | 112 |
| 4.4.1.4. | Eğitim ve Test Verisinin Oluşturulması..... | 115 |
| 4.4.2. | Yapay Sinir Ağının Eğitimi ve Testi..... | 115 |
| 4.5. | YAPAY SİNİR AĞI TEKNOLOJİSİNİN DEĞERLENDİRİLMESİ..... | 117 |
| 4.6. | YAPAY SİNİR AĞI KULLANIM ALANLARI..... | 120 |
| 4.7. | MUHASEBE BİLGİ SİSTEMİ VE YAPAY SİNİR AĞI TEKNOLOJİSİ İLİŞKİSİ..... | 120 |
| 4.8. | YAPAY SİNİR AĞININ FİNANSAL BAŞARISIZLIĞI ÖNGÖRMEDE KULLANIMI..... | 125 |

BEŞİNCİ BÖLÜM

FİNANSAL BAŞARISIZLIĞIN ÖNGÖRÜLMESİNDE YAPAY SİNİR AĞI KULLANIMINA İLİŞKİN AMPİRİK BİR ÇALIŞMA

| | | |
|--------|--|-----|
| 5.1. | ÇALIŞMADA KULLANILAN ÖRNEKLEM..... | 140 |
| 5.2. | ÇALIŞMADA GELİŞTİRİLEN MODELLER | 145 |
| 5.2.1. | Ayırma Analizi Modelinin Geliştirilmesi | 146 |
| 5.2.2. | Yapay Sinir Ağı Modelinin Geliştirilmesi | 149 |
| 5.3. | BULGULAR VE DEĞERLENDİRME..... | 151 |
| | SONUÇ | 157 |
| | KAYNAKLAR..... | 161 |
| | EKLER..... | 168 |

Tablolar

| | |
|---|-----|
| Tablo 1.1 : Finansal başarısızlık tanımları..... | 14 |
| Tablo 1.2 : Finansal başarısızlığın algılanmasındaki farklılıklar..... | 16 |
| Tablo 3.1 :Başarısız ve başarısız olamayan işletmelerin ortalamaları ve F değerleri | 34 |
| Tablo 3.2 : Zeta Analizinin değişik sürelerdeki performansı | 37 |
| Tablo 3.3 : Standart sapmanın ayırma fonksiyonunun başarısına etkisi | 42 |
| Tablo 3.4 : Hing-Lau tarafından geliştirilen 3 modelin öngörü başarıları..... | 45 |
| Tablo 3.5 : Aziz, Amanuel ve Lawson tarafından naki akımı verilerine dayalı logit tekniği ile elde edilen sınıflandırma doğruluğu..... | 50 |
| Tablo 3.6: Uzman sistem ile ayırma analizi-insan yargısı ve grup yargısının performans karşılaştırması | 70 |
| Tablo 4.1 : Öğrenme algoritmaları ve uygulandıkları alanlar | 113 |
| Tablo 4.2 : Yapay sinir ağı ve ayırma analizinin yıllar itibariyle doğru sınıflandırma oranları | 128 |
| Tablo 4.3 : Değişik temel orana sahip veri setleri | 130 |
| Tablo 4.4 : Deney grubu verilerde ayırma analizi ve yapay sinir ağı modelinin doğru sınıflandırma oranları | 131 |
| Tablo 4.5 : Kontrol grubu verilerde ayırma analizi ve yapay sinir ağı modellerinin doğru sınıflandırma oranları..... | 131 |
| Tablo 4.6 : Logit ve yapay sinir ağının doğru sınıflandırma oranları..... | 134 |
| Tablo 4.7 : Logit ve yapay sinir ağının değişik kopuş noktaları ile doğru sınıflandırma oranları..... | 135 |
| Tablo 5.1 : Ayırma analizinin deney verileri üzerindeki doğru sınıflandırma oranları..... | 151 |
| Tablo 5.2 : Ayırma analizinin kontrol verileri üzerindeki doğru sınıflandırma oranları..... | 153 |
| Tablo 5.3 : Yapay sinir ağının kontrol verileri üzerindeki doğru sınıflandırma oranları..... | 153 |

Şekiller

| | |
|--|-----|
| Şekil 3.1 : Beaver'in çalışmasında elde ettiği kopuş noktaları | 31 |
| Şekil 3.2 : İşletmelerin değişik kredi politikalarına geçişi. | 58 |
| Şekil 3.3 : Kredi politikasında felaket teorisi modeli..... | 59 |
| Şekil 3.4 : Çok değişkenli ayırma analizi ve döngüsel bölümlene analizi arasındaki farklılık..... | 61 |
| Şekil 4.1 : Biyolojik neuron ve yapısı | 87 |
| Şekil 4.2 : Yapay neuron (artificial neuron)..... | 91 |
| Şekil 4.3 : Yapay sinir ağı modeli | 92 |
| Şekil 4.4 : Toplam ve geçiş fonksiyonu | 94 |
| Şekil 4.5 : Değişik geçiş fonksiyonları..... | 96 |
| Şekil 4.6 : Bir neuronun işleyişine örnek | 98 |
| Şekil 4.7 : Öğrenme süreci ve öğrenme algoritması | 99 |
| Şekil 4.8 : Öğrenme süreci ve hatanın hesaplanması | 101 |
| Şekil 4.9 : Delta algoritmasında ağırlık değişimi | 105 |
| Şekil 4.10 : Temel yapay sinir ağı mimarileri | 108 |
| Şekil 4.11 : Ağdaki katman sayısı ve ağı sınıflandırma yeteneği | 111 |
| Şekil 4.12 : Genelleme ve ezberleme | 117 |
| Şekil 4.13 : Verileri ezberleyen ve iyi genellemeye ulaşan ağlardaki hata eğrileri..... | 117 |
| Şekil 4.14 : İşletme bilgi sistemleri ve muhasebe bilgi sisteminin yeri | 123 |

KISALTMALAR

A.g.e : Adı geen eser

C : cilt

Ed. : edition

Inc. : incorporated

Int. : international

İİK : İcra İflas Kanunu

m. : madde

N : No

p. : page

pp. : pages

R.G. : Resmi Gazete

s. : sayfa

SPK : Sermaye Piyasası Kanunu

ss. : sayfalar

TTK : Trk Ticaret Kanunu

V : volume

Yay. : yayın

GİRİŞ

Geçmişe ait ekonomik faaliyetlerin sonuçlarının ortaya konduğu muhasebe raporları finansal analiz yardımı ile bilgi kullanıcılarının gereksinim duyduğu, geleceğe yönelik bilgiler haline getirilmektedir. Finansal analiz kapsamında, tüm bilgi kullanıcılarının ilgilendikleri temel konu; işletmelerin gelecekte faaliyetini sürdürüp sürdüremeyeceği, bir başka deyişle finansal başarısızlık riskidir. Finansal başarısızlık erken öngörülebildiği ölçüde, bilgi kullanıcılarının verdikleri kararlar daha sağlıklı hale gelecektir.

Finansal başarısızlığın öngörülmesinde, finansal bilgilerin ve finansal oranların değişken olarak kullanıldığı istatistik tekniklere dayalı modeller, yaygın olarak ve başarı ile kullanılmaktadır. Özellikle birden fazla finansal oranın aynı anda değerlendirilmesine olanak veren çok değişkenli istatistik teknikler, finansal başarısızlığın öngörülmesi çalışmalarında en çok başvurulan tekniklerdir. Ancak bu istatistik tekniklerin finansal başarısızlık alanına uygulanmalarında, istatistik tekniklerin varsayımlarının gerçekleşmemesi, söz konusu çok değişkenli istatistik tekniklerin finansal başarısızlık alanına uygulanmaya elverişli olmamaları

gibi çok sayıda sorun yaşanmaktadır.

Yapay zeka alanında son yıllarda yaşanan gelişmeler uzman sistem, yapay sinir ağı, bulanık mantık ve genetik algoritmalar şeklindeki bilgi işlem teknolojilerini kullanılabilir hale getirmiştir. Bu teknikler içinde yapay sinir ağı teknolojisi, çok sayıda değişkenin birbiri ile karmaşık ilişki içinde bulunduğu örüntüleri tanımlayabilmesi nedeniyle muhasebe –finans alanındaki problemlerin çözümünde uygun bir araç durumundadır. Özellikle çok fazla değişkenin bulunduğu ve karmaşık bir problem alanı sunan finansal başarısızlığın öngörülmesi konusunda, yapay sinir ağı teknolojisinin umut verici sonuçlar ürettiği görülmektedir.

Bu çalışmada finansal başarısızlığın öngörülmesi alanında, istatistik tekniklere karşı alternatif olarak, yapay sinir ağı teknolojisi ile yüksek öngörü doğruluğuna sahip bir model geliştirilmesi amaçlanmaktadır.

Bu doğrultuda çalışma 5 bölümden oluşmaktadır.

Birinci bölümde çalışmanın amacı kapsamı ve yöntemi özetlenmeye çalışılmıştır. İkinci bölüm, finansal başarısızlık kavramı ve finansal başarısızlığın öngörülmesinin önemine ayrılmıştır. Üçüncü bölüm finansal başarısızlığın öngörülmesinde kullanılan modellerin incelenmesi ve bu modellerden matematiksel -istatistiksel olanların değerlendirilmesinden oluşmaktadır. Yapay sinir ağlarına ilişkin kuramsal bilgilerin verildiği dördüncü bölümde, ayrıca yapay sinir ağların finansal başarısızlığın öngörülmesi alanına uygulanışı ele alınmaktadır. Beşinci ve son bölüm, finansal başarısızlığın öngörülmesinde yapay sinir ağı kullanımına ilişkin ampirik bir uygulamayı içermektedir.



BİRİNCİ BÖLÜM

CALIŞMANIN AMACI, KAPSAMI ve YÖNTEMİ

BİRİNCİ BÖLÜM

ÇALIŞMANIN AMACI, KAPSAMI ve YÖNTEMİ

1.1.ARAŞTIRMANIN AMACI

İşletme açık ve dinamik bir sistem olup sürekli olarak çevresi ile ilişki içindedir. Bu nedenle işletme ile çıkar ilişkisi içinde olan çok sayıda grup bulunur. Bunlar yöneticiler, ortaklar, olası yatırımcılar, kredi verenler, çalışanlar, alıcılar-satıcılar ve devlettir. Bu gruplar ilişkileri gereği sürekli olarak işletme ile ilgili karar almak zorundadırlar. Örneğin işletmeye kredi verenlerin işletmeye kredi verme - vermeme kararı, olası yatırımcıların yatırım yapma yapmama kararı bu kararlara örnek verilebilir.

Çıkar grupları bu kararları verirken, kararlarını büyük ölçüde muhasebe bilgilerine dayandırır. Ancak muhasebe bilgilerine dayanarak karar verilirken önemli bir sorun ortaya çıkar. Çıkar gruplarının kararları gelecekle ilgili iken, bu kararların dayandırıldığı muhasebe bilgileri daha çok geçmişe ilişkin bilgilerdir. Örneğin en önemli muhasebe bilgilerini içeren finansal raporlardan biri olan bilanço, çıkarıldığı günün; gelir tablosu ise geçmiş bir yıllık

dönemin bilgilerini içerir. Bu nedenle, muhasebe bilgilerinin doğrudan doğruya kararlarda kullanılması, her zaman için uygun olmayacaktır.

Muhasebe bilgilerinin karar almada kullanılabilmesi için analiz edilmesi ve yorumlanması, bu yolla da öngörüler haline getirilmesi gerekir. Bu görev muhasebenin analiz - yorum işlevini oluşturur ve "finansal analiz" kapsamında ele alınır.

Finansal analizde, muhasebe bilgilerine dayalı olarak öngörülerde bulunurken değişik yöntemlerden yararlanır. Bu yöntemler karşılaştırmalı finansal tablolar analizi, yüzde analizi, trend analizi ve oran analizi yöntemleridir. Ancak bunların içinde oran analizi yöntemi dışındakiler daha çok deneyim ve sezgiye dayalı teknikler oldukları için uygulanmaları zaman alıcı, zor ve varılan sonuçların hata taşıma olasılığı yüksektir. Buna karşın uygulanma kolaylığı ve hızı, basitliği, ayrıca teorik bir çatı sunması nedenleriyle oran analizi en yaygın kullanılan ve tercih edilen finansal analiz tekniği durumundadır.

Muhasebe öngörülerinde oran analizinin belki de en başarılı uygulamaları "finansal başarısızlığın öngörülmesi" alanındadır. Finansal başarısızlığın öngörülmesi, tüm çıkar gruplarını yakından ilgilendirmesi nedeniyle her zaman araştırmacıların ilgisini çeken bir konu olmuştur. Bu alanda istatistiksel - matematiksel tekniklerin de yardımıyla oranların değişken olarak kullanıldığı çok sayıda model geliştirilmiştir. Bu modelleri geliştirmede başta çok değişkenli ayırma analizi olmak üzere, çok değişkenli regresyon, logit ve probit gibi çok değişkenli analiz teknikleri en çok başvurulan istatistik tekniklerdir. Yazında bu teknikler kullanılarak geliştirilen ve finansal başarısızlığı öngörmeye oldukça iyi sonuçlar üreten çok sayıda model bulunmaktadır. Ancak oranların değişken olarak kullanıldığı matematiksel - istatistiksel tekniklere dayalı modellerde karşılaşılan bir dizi önemli sorun bulunmaktadır. Bu çalışmanın da hareket noktasını oluşturan bu sorunların başında, istatistik tekniklerin

dayandığı varsayımların oranların değişken olarak kullanıldığı durumlarda çığnemek zorunda kalınmasıdır. Bu nedenle geliştirilen modeller her ne kadar başarılı olsalar da, elde edilen başarıların genelleştirilmesinde metodolojik zorlukla karşılaşılır. Karşılaşılan bir diğer sorun, bir işletme için bir oranın, o işletme için olumsuz bir durum yaratmazken, aynı oran değeri başka bir işletme için olumsuzluk yaratmasıdır. Ayrıca oranlarla yapılan çalışmalarda kullanılan veriler içinde eksik, çok uç değerlerle karşılaşılması da sık yaşanan bir sorundur. İstatistik tekniklerin bu tip örüntüleri tanımlamakta yetersiz kaldığını söylemek yanlış olmayacaktır.

İstatistiksel - matematiksel modellerin kullanılması durumunda ortaya çıkan bu sorunların aşılmasını sağlayacak, oranları değişken olarak kullanan, istatistiksel- matematiksel modeller kadar veya daha fazla öngörü başarısına sahip alternatif bir model geliştirilmesi bu çalışmanın temel amacını oluşturmaktadır.

Uygun model arayışı, yapay zeka teknolojilerinden yapay sinir ağı teknolojisinin, sunduğu avantajlar nedeniyle, alternatif modelin geliştirilmesinde kullanılabileceğini ortaya çıkarmıştır. Bu çalışmada, yukarıda belirtilen temel amaç doğrultusunda, yapay sinir ağının finansal başarısızlığın öngörülmesinde kullanılıp kullanılmayacağı araştırılacaktır.

1.2.ARAŞTIRMANIN KAPSAMI

Araştırma kapsamını, finansal başarısızlığın öngörülmesi yazının incelenmesi ve finansal başarısızlığın öngörülmesinde yapay sinir ağı kullanımına ilişkin bir ampirik uygulama oluşturmaktadır.

Yazın taramasında, 1968-1997 yılları arasında muhasebe ve finans alanındaki yazın taranarak; finansal başarısızlık alanındaki çalışmalar, kullandıkları değişkenler, örneklem,

izlenen yöntem ve ulaşılan sonuçlar bakımından özetlenmiştir. İncelenen çalışmalar içinde özellikle yüksek öngörü doğruluğu sağlayan modellere ve daha fazla referans olarak verilen çalışmalara ağırlık verilmiştir. Yapay sinir ağı teknolojisi yazını da, yapay sinir ağı teknolojisi alanında kuramsal temel sağlayacak şekilde ve ampirik uygulama doğrultusunda taranmıştır.

İkinci olarak yapılan ampirik çalışmada kapsamında; Sermaye Piyasası Kanunu'na tabi ve/veya İstanbul Menkul Kıymetler Borsasında işlem gören, üretim, hizmet ve ticaret sektöründe, 1983-1997 yılları arasında faaliyet gösteren işletmelerden oluşturulan örneklem üzerinde, ayırma analizi tekniği ve yapay sinir ağı teknolojisi ile birer model geliştirilmiştir. Araştırma kapsamında yapay sinir ağı ile karşılaştırmada ayırma analizinin kullanılmasının nedeni, yazında en başarılı modellerin ayırma analizi ile kullanılması ve en yaygın uygulanan tekniklerden biri olmasıdır.

1.3.ARAŞTIRMANIN YÖNTEMİ

Araştırmada öncelikle finansal başarısızlığın öngörülmesi ve yapay sinir ağları konusunda yazın taraması şeklinde bir yöntem izlenmiştir.

Ampirik çalışma bölümünde, finansal başarısızlığın öngörülmesi amacıyla deney grubu verileri üzerinde ilk olarak ayırma analizi ve yapay sinir ağı ile iki model geliştirilmiştir. Sonrasında geliştirilen modellerin kontrol verileri üzerindeki doğru sınıflandırma oranları ölçülmüştür. Örneklem düzeyinde elde edilen sonuçların evren ölçeğinde geçerliliğinin test edilmesi amacıyla da, oranlar arası farkın anlamlılığı hipotez testi yapılmıştır. Hipotez testi sonuçları temel alınarak bulgular genellenmiştir.



İKİNCİ BÖLÜM

FİNANSAL BAŞARISIZLIK

İKİNCİ BÖLÜM

FİNANSAL BAŞARISIZLIK

2.1. FİNANSAL BAŞARISIZLIK KAVRAMI

Bu çalışmada finansal başarısızlık kavramıyla karşılaşıldığında akla ilk gelebilecek soru, niçin iflas kavramı yerine “finansal başarısızlık” kavramının tercih edildiği olacaktır. Bu nedenle finansal başarısızlık kavramının tanımı yapılmadan önce bu sorunun yanıtı verilmeye çalışılacaktır.

Finansal başarısızlık kavramı, yazındaki diğer çalışmalarda da olduğu gibi, özellikle seçilmiş bir kavramdır.¹ Bu çalışmada iflas kavramı yerine, finansal başarısızlık kavramının kullanılmasının nedenleri şu şekilde sıralanabilir :

- a) Finansal başarısızlık kavramının kullanılmasının en temel nedeni, gerçek hayatta işletmelerin çok azının içinde buldukları finansal zorlukları iflasla

¹ AKTAŞ Ramazan, Endüstri İşletmeleri İçin Finansal Başarısızlık Tahmini – Çok Boyutlu Model Uygulaması, Türkiye İş Bankası Yay. No:323, Ankara 1993, s.5.

sonlandırmalarıdır. Çoğu durumda finansal zorluk yaşayan işletmeler, finansal zorluklarının son aşamasını; anlaşma yoluyla borçların ertelenmesi, borçluların işletmeye ortak yapılması, el değiştirme, sabit varlıklarının bir kısmının elden çıkarılması, üretimin durdurulması gibi yollarla aşmakta ya da son çare olarak işletme el değiştirmektedir. Hatta geçmişte ülkemizde görüldüğü gibi, bu tür zorluklarla karşılaşan işletmeler doğrudan devlet tarafından kurtarılmaktadır. Bu nedenle iflasını açıklamış işletme sayısı gerçek durumu yansıtmaktan uzaklaşmakta ve istatistiksel açıdan değerlendirilemeyecek kadar küçülmektedir.² Örnek olarak; Metaş A.Ş. 1990 yılında tüm göstergeler işletmenin iflas aşamasında olduğunu göstermekte iken, 20 Nisan 1992 tarihinde üretimini durdurmuş; ancak 4 Temmuz 1992 tarihinde borçlu bulunan bankaların, borçları oranında işletmeye ortak olmalarıyla özsermayesi takviye edilmiştir. Sonuçta işletme tekrar varlığını sürdürebilme olanağına kavuşmuştur.

- b) İkinci olarak, değişik şekillerde finansal zorluk içinde bulunan işletmeleri de “finansal başarısızlık” kavramının içine dahil ederek öngörmenin pragmatik sonuçları, sadece iflas etmiş olan işletmeleri öngörmenin pragmatik sonuçlarından daha fazla olmasıdır. Finansal açıdan zor durumda olan işletmeleri öngörmek, yatırımcılar, kredi verenler gibi karar vericiler açısından sadece iflas eden işletmeleri öngörmekten daha önemli olduğu söylenebilir.

² Ancak ülkemizdeki iflas eden işletmelere ait, Sanayi ve Ticaret Bakanlığında, Türkiye Odalar ve Borsalar Birliğinde, Devlet İstatistik Enstitüsünde, Adalet Bakanlığında ve diğer bazı ilgili kuruluşlarda tutulmuş herhangi düzenli bir istatistik bilgiye rastlanmamıştır.

Gerek iflasını açıklamış işletme sayısının azlığından dolayı, örneklem sayısının yetersizliği ve gerekse finansal açıdan zor durumda olan işletmeleri öngörmenin yararı dikkate alındığında, işletme sayısı açısından daha geniş bir kitleyi kapsayan ve bilgi kullanıcıları açısından ilgili bilgi yaratmaya yardımcı olacak, “finansal başarısızlık” gibi bir kavramın tercih edilmesini gerektirmiştir.

Finansal başarısızlık kavramına ilişkin tanımları, yasal ve teknik olmak üzere iki başlıkta toplamak mümkündür. Yasal ve teknik alanda yapılan değişik tanımlarda da, çok farklı durumların finansal başarısızlık kavramı içinde değerlendirilmesi dikkat çekicidir.

Hukuksal açıdan finansal başarısızlık kavramı, başta Türk Ticaret Kanunu olmak üzere, İcra İflas Kanunu, Sermaye Piyasası Kanunu, Bankalar Kanunu ve Şirket Kurtarma Kanunu olarak anılan 3332 Sayılı Kanun’da tanımlanmaktadır.³

Türk Ticaret Kanunu (TTK) finansal başarısızlığı “şirketin mali durumunun bozulması” olarak ifade ederek, bu durumu sermayenin yarısı veya üçte ikisinin kaybolması durumunda “acizlik”; şirket aktiflerinin alacaklıların alacaklarını karşılayamamasını ise “iflas” kavramıyla tanımlamıştır.⁴ Ayrıca vadesi gelen borçların vadesinde ödenememesi de acizlik olarak belirtilirken, acizlik veya başka nedenlerle ödemelerin yapılmamış veya yapılamamış olması “ödemelerin tatili”, borçların aktifleri aşması durumu da “borca batıklık” şeklinde tanımlanmaktadır. TTK borca batıklık hali oluşmadan sermayenin yarısı kaybedildiğinde

³ 3332 sayılı Sermaye Piyasasının Teşviki, Sermayenin Tabana Yaygınlaştırılması ve Ekonomiyi Düzenlemede Alınacak Tedbirler ile 5422 sayılı Kurumlar Vergisi Kanunu, 213 Sayılı Vergi Usul Kanunu ve 3182 sayılı Bankalar Kanununda Değişiklik Yapılması Hakkında Kanun, R.G. 31 Mart 1987 ve Sayı :19417 (Mükerrer), s.1.

⁴ Türk Ticaret Kanunu, m.324.

gerekli tedbirlerin alınmasını da öngörmektedir.⁵

Mevzuatımızda finansal başarısızlığın tanımı için başvurulacak diğer önemli bir kaynak da İcra İflas Kanunu (İİK) 'dur. İİK' nu, borçların mevcut ve alacaklardan fazla olması durumunda, idare veya temsille görevli kimselerin ya da tasfiye memurlarının beyanı veya alacakların ispatıyla iflasa (önceden takibe gerek kalmaksızın) karar verebileceğini kabul etmiştir.⁶ Kanun ayrıca ödemelerin tatil edilmesinin, alacaklıların talebiyle iflas sayılacağını da belirtmektedir.⁷

Sermaye Piyasası Kanunu (SPK) finansal başarısızlık için kesin bir ölçü koymayıp; sadece "sermayenin azalması veya kaybı", "mali yapının ciddi surette zayıflaması", "mali durumun taahhütleri karşılayamayacak kadar zayıflamış olması" şeklindeki ifadelere yer vermiştir. Kanun bu durumlardan birincisinde; Sermaye Piyasası Kurul' una mali yapının düzeltilmesi için tedbir alınmasını ve öngörülen işlemlerin yapılmasını isteyebilme, ilgili mercilere bildirme, bu işlemlerin hukuka aykırılığının tespiti ve iptali için dava açma konularında yetki vermiştir. Ancak özellikle ikinci ve üçüncü durumlarda, Sermaye Piyasası Kurulu'na kurumların yetkilerini süre belirtmeksizin kaldırma, hatta bu tedbirlerin sonuç vermemesi durumunda doğrudan iflaslarını isteyebilme yetkisi verilmiştir.⁸ İkinci ve üçüncü durumun SPK açısından finansal başarısızlık değerlendirmesinde daha kötü bir durumu işaret ettiği anlaşılmaktadır.⁹

⁵ KAYAR İsmail, *Anonim Ortaklıkta Mali Durumun Bozulması ve Alınacak Tedbirler*, Mimoza Yay. No: 54, Konya, 1997, s.35-36.

⁶ İcra İflas Kanunu, m.179.

⁷ *Ag.k.*, s.177.

⁸ Sermaye Piyasası Kanunu, m.46.

⁹ KAYAR, *A.g.e.*, s. 33.

Şirket kurtarma kanunu olarak bilinen 3332 sayılı kanunun geçici birinci maddesine göre şirket kurtarmayla ilgili ikinci bölümünün çoğu 31.12.1989 tarihinde yürürlükten kalkmıştır. Ancak, kanunda bu tarihe kadar yararlanan işletmeler açısından yürürlükte olan maddeleri bulunduğu ve doğrudan finansal başarısızlıkla ilgili olduğu için, bu yasa tarafından yapılan tanımlara da burada yer verilmiştir. Bu kanunda finansal başarısızlık için net bir tanımlama yapılmayıp sadece “finansman güçlüğü içinde bulunma” ve “sermaye yapısının zayıflaması” tanımlamaları kullanılmıştır.¹⁰

Bankalar kanunu ise benzer şekilde “mali bünyenin zayıflaması” ve “mali bünyenin ciddi bir şekilde zayıflaması” kavramlarına yer vermiştir.¹¹

Finansal başarısızlık kavramı teknik açıdan incelendiğinde ise herkesin üzerinde anlaşığı bir tanıma rastlanmamaktadır. Finansal başarısızlığın öngörülmesi konusundaki yazında yapılmış belli başlı çalışmalarda, finansal başarısızlık için kullanılan kavramlar ve tanımları Tablo 1.1’de özetlenmiştir.

¹⁰ 3332 Sayılı Kanun,

¹¹ Bankalar Kanunu, m.64.

Tablo 1. 1: Finansal Başarısızlık Tanımları

| Yazar | Kullanılan Kavram | Kullanılan Tanım |
|-----------------------|-------------------|--|
| Altman | İflas | Yasal olarak iflas etmiş ve kayyum atanmış veya Amerika ulusal iflas yasası altında yeniden yapılanması onaylanmış işletmeler |
| Beaver | Başarısızlık | Vadesi gelmiş borçlarını ödeyememe, iflas etme, tahvil faizinin ödenmemesi, karşılıksız çek yazılması veya imtiyazlı hisse senetlerine kar payının ödenmemesi |
| Blum | Başarısızlık | Vadesi gelmiş borçların ödenmemesi, iflas sürecine başlamış olmak, borçlar konusunda kredi verenlerle borçların bir kısmının silinmesi konusunda anlaşma |
| Deakin | Başarısızlık | İflas etmiş, tasfiye edilmiş veya kredi verenler tarafından likidite dönüştürülmüş işletmeler. |
| Edminster | Başarısızlık | Yazar Beaver ve Blum'un tanımları arasında fark gözetmemiştir. |
| Elam | İflas | Aşağıdaki durumlardan birinin gerçekleşmiş olması: <ul style="list-style-type: none"> • ABD Federal iflas yasasının X ve XI bölümleri gereğince işletmenin yeniden yapılandırılmasını seçmiş veya genel kurulda oylanmış olması • Kredi verenlerle borçların bir kısmının silinmesi konusunda anlaşmaya varmış olmak |
| El Hennaway ve Morris | Başarısızlık | İşletmenin likidite edilmesi veya mahkemece kayyum atanması |
| Taffler | Başarısızlık | Kayyum atanması, işletmenin gönüllü likidite edilmesi mahkeme kararıyla tasfiye |
| Aktaş | Başarısızlık | Diğer yazarların kullandıkları tanımlara ek olarak üç yıl üst üste zarar etme, mali kriz nedeniyle üretimi durdurma |

Kaynak: GORDON V. Karels and ARUN J. Prakash, "Multivariate Normality and Forecasting of Business Bankruptcy", *Journal of Business Finance and Accounting*, C:14, N:4 (Winter 1987), p. 576; AKTAŞ Ramazan, *Endüstri İşletmeleri İçin Finansal Başarısızlık Tahmini – Çok Boyutlu Model Uygulaması*, Türkiye İş Bankası Yay. No:323, Ankara 1993, s.8.

Bu çalışmada, bilgi kullanıcıları açısından iflastan önceki değişik finansal başarısızlık durumlarını öngörmenin sağlayacağı pragmatik sonuçlar dikkate alınarak ve örneklem hacmini geniş tutmak gereğiyle finansal başarısızlık kavramı için; "işletmenin, iflas etmiş olması, borçların ertelenmesi, borçların ödenememesi, üretimin durdurulması, üç yıl üst üste zarar etmiş olma, şirket kurtarma yasası gereğince kurtarılmış olma, sermayenin yarısının veya 2/3'nün kaybolması, borçların aktifini aşması, aktifin %10'nun kaybedilmesi şartlarından birine uygunluk" şeklinde bir tanım benimsenecektir. Bu ölçütlerden birine uyan işletmeler "finansal açıdan başarısız işletme" veya bu ifadenin uzunluğundan dolayı sadece "başarısız işletme" olarak anılacaktır.

Çalışmada finansal başarısızlık kavramının karşıtı olarak da "finansal başarısız olmayan işletme" veya kısaca "başarısız olmayan işletme" kavramı kullanılacaktır. Bu kavramın kullanılmasının altında yatan neden, "finansal başarısız olmayan" işletmelerin tümünün, "finansal açıdan başarılı" olarak kabul etmek konusunda yaşanan güçluktur. Bir işletmeyi finansal açıdan başarısız kabul etmek için, yukarıda konu edilen değişik ölçütler bulunabilmesine rağmen; bir işletmeyi finansal açıdan başarılı kabul etmek için, aynı objektiflikte ölçütler koymak mümkün olmamaktadır. Çünkü başarı duruma göre değişen, göreceli bir kavramdır. Bu çalışmada finansal başarısız olmayan işletme kavramı için; "finansal başarısızlık ölçütüne uymamak" şeklinde bir tanım benimsenecektir.

2.2. FİNANSAL BAŞARISIZLIĞIN NEDENLERİ VE ETKİLERİ

2.2.1. Finansal Başarısızlığın Nedenleri

İşletmeleri finansal başarısızlığa götüren çok sayıda neden bulunmaktadır. Bu nedenler birden ortaya çıkarak işletmeyi aniden başarısız duruma getirmezler; genellikle belli bir süreç içinde etkilerini gösterirler ve eğer bu nedenleri ortadan kaldıracak bir önlem alınmaz ise süreç finansal başarısızlığın değişik şekilleriyle son bulur. Başarısız duruma düşmüş işletmelerde karşılaşılan en önemli sorun, olumsuz gelişmelerin doğru şekilde algılanamamasıdır. Nitekim 570 işletme üzerinde yapılan bir araştırmada; işletmeleri başarısızlığa götüren nedenler açısından, işletme içindeki bireyler ile işletme dışındaki bireylerin, farklı değerlendirmelere sahip oldukları görülmektedir (Tablo 1.2).

Tablo 1. 2 : Finansal Başarısızlığın Algılanmasındaki Farklılıklar

| Finansal Başarısızlığın Nedeni | İşletme Görüşü | Sahiplerinin Görüşü | Kredi Verenlerin Görüşü |
|---|----------------|---------------------|-------------------------|
| İşletme Depresyonu | 68 | | 29 |
| Yetersiz Yönetim | 28 | | 59 |
| Yetersiz Sermaye | 48 | | 33 |
| Alacak Tahsil Sorunları | 30 | | 18 |
| Rekabet | 40 | | 9 |
| İşletme Varlıklarında Değer Kayıpları | 32 | | 6 |
| İşletme Yeri Seçiminde Yanlışlık | 15 | | 3 |
| Borçlardaki Faiz Oranının Aşırı Değişmesi | 11 | | 2 |
| Ticari Alanda Öngörülemeyen Değişiklikler | 11 | | 2 |

Kaynak : BARTOL Kathryn M.-MARTIN Davit C., **Management**, McGraw-Hill Inc., New York,1991, p.798.

Finansal başarısızlığın öngörülmesinde kullanılan modeller, gerçekte finansal

başarısızlığa ilişkin bulguların, finansal tablolardan elde edilmesi ve değerlendirilmesi işlevini görmektedirler. Böylelikle işletmeyle ilgili taraflar, finansal başarısızlığın ortaya çıkış süreci hakkında gerçekçi bilgiler elde etme olanağı bulmaktadır. Finansal başarısızlığın nedenlerinin bilinmesi, bu modellerin işleyişinin anlaşılması, sonuçlarının değerlendirilmesi ve finansal başarısızlığın önlenmesi için gerekli olduğu söylenebilir.

Ancak finansal başarısızlığın çok sayıda nedeni bulunması dolayısıyla bunlardan en önemlileri ele alınarak incelenecektir. Finansal başarısızlığın nedenlerini mikro ve makro olmak üzere iki boyutta incelemek olanaklıdır. Mikro boyutta işletme içinden kaynaklanan nedenler, makro boyutta ise işletmenin çevresini oluşturan koşullardan kaynaklanan nedenler söz konusu olmaktadır.¹²

Finansal başarısızlığın mikro boyuttaki nedenleri ortaya çıkış dönemlerine göre yatırım döneminde ve işletme döneminde olmak üzere iki gruba ayrılabilir.¹³

Yatırım döneminde başarısızlık nedenleri olan faktörler arasında optimal sermaye yapısının oluşturulamaması, pazar ve tüketici yapısının sağlıklı olarak ortaya konmaması, pazara giriş zorlukları, yanlış üretim metodu seçilmesi, yönetici ve personel yetersizlikleri, hammadde ve malzemede yaşanan tedarik sorunları, işletme faaliyetlerinin patent, lisans gibi anlaşmalarla sınırlandırılması, kapasite sorunları, proje ile uygulama arasında gerçekleşen farklılıklar sayılabilir.¹⁴

¹² BÜKER Semih, AŞIKOĞLU Rıza, SEVİL Güven, **Finansal Yönetim**, Eskişehir, Ekim 1994, s.388-395.; AKGÜÇ Öztin, **Finansal Yönetim**, Muhasebe Enstitüsü Yayın No :56, İstanbul, 1989, s.743-745.

¹³ A.g.e., s.389. ;AKGÜÇ, A.g.e.,s.743-745.

¹⁴ BÜKER-AŞIKOĞLU-SEVİL, A.g.e., s.389-390.

İşletmeleri yatırım döneminden sonraki dönemlerdeki yönetim yetersizlikleri, planlama sorunları, istihdam sorunları, satış düzeyinin yetersizliği, sabit ve değişken maliyetlerde beklenmedik yükselmeler, aşırı rekabet, finansal planlama ve yönetim sorunları, nakit yönetimindeki eksiklikler ve nakit yükümlülüklerinin yerine getirilmemesi, stok politikasındaki yanlışlıklar, satış ve kredi politikasındaki yanlışlıklar, satış ve üretim bölümleri arasındaki uyumsuzluklar, kalite sorunları, dağıtım kanalı seçiminde ve oluşturulmasındaki sorunlar, verimlilik sorunları, çağdaş işletmecilik tekniklerine uyumsuzluk, toplu sözleşme, grev ve lokavtlar sonucu oluşan olumsuz çalışma düzenleri başarısızlığa götüren nedenler olarak karşımıza çıkmaktadır.¹⁵

İşletmeleri başarısızlığa götüren yukarıdaki nedenlere, işletmenin çevresinden kaynaklanan makro nedenler olarak başta ekonomide meydana gelen değişiklikler olmak üzere, toplumsal değişiklikler, yasal ortamda meydana gelen değişiklikler ile doğal çevredeki değişiklikler eklenebilir.

Ekonomik yapıdaki değişiklikler işletmeleri doğrudan ve kısa sürede etkilemesi bakımından, işletme başarısızlıklarının nedenleri içinde ilk sıralarda yer alır. İşletmenin ürettiği mal ve hizmetlere olan talep, kullanılacak kredilere uygulanacak faiz oranı, işletmenin dağıttığı kar payı miktarı, kullanılan hammadde ve malzemelerin fiyatları ile çalışanlara ödenen ücretler, ekonomideki enflasyon, para politikaları, faiz oranları gibi faktörler bunlardan birkaçıdır. Bunlardaki olumsuz değişiklikler işletmeler açısından başarısızlık doğurabilecek önemli birer nedendir.

¹⁵ A.g.e., s.390-391.

İşletmenin içinde bulunduğu toplumsal yapıdaki kültürel, demografik, politik, dinsel faktörler işletmelerin hayatını etkileyebilecek önemli etkenlerdir. Kültürel, politik veya dinsel nedene dayalı olarak finansal başarısızlık yaşayan işletme örneklerine, günümüz globalleşen dünyasında sıkça rastlanır olmuştur. Yasal çerçeve içinde bulunmak zorunda olan işletme, yasal yaptırımlar sonucu faaliyetini devam ettirememeye durumuyla karşılaşabilir. Ayrıca günümüzde önemi giderek artan doğal kaynakların korunmasına yönelik önlemler de işletmeleri finansal açıdan olumsuz etkileyebilecek güçlerden biridir.¹⁶

2.2.2.Finansal Başarısızlığın Etkileri

Finansal başarısızlık sonucu öncelikle işletmeye bağlanan ekonomik değerlerde önemli azalışlar veya kayıplar söz konusu olmaktadır. Bu işletmeye fon sağlayan ortak ve alacaklıların bağladıkları bu fonların kayba uğraması anlamına gelmektedir. Alacaklıların hakları ortaklara göre daha fazla korunmuş olsa da, işletme varlıklarının tüm yükümlülükleri karşılamaya yetmediği durumda alacaklılar da bekledikleri faizin, hatta anaparanın geri dönmemesi riskini taşırlar. Tasarrufçuların bu tür kötü deneyimleri sermaye veya para piyasasından kaçmalarına neden olabileceği gibi, işletmeye önemli oranda yatırım yapan iştirakçilerin veya kredi veren alacaklıların ekonomik durumlarının bozulmasına varacak ölçüde etkileri olabilir. Finansal açıdan başarısız olmuş işletmenin yaratacağı istihdam boşluğu ve milli gelirdeki azalma diğer başka olumsuz etkiler arasında sayılabilir.

Finansal başarısızlığı, ekonominin genelinde kaynakları verimsiz kullanan işletmelerin ortadan kaldırılması şeklinde olumlu olarak kabul eden diğer başka bir görüşe göre de;

¹⁶ A.g.e.

finansal başarısızlık içinde özellikle iflas, kanayan yaranın kapanması şeklinde değerlendirilmektedir.

2.3. FİNANSAL BAŞARISIZLIĞIN ÖNGÖRÜLMESİNİN ÖNEMİ

Bir bilimsel çalışmanın amacı, sadece bilimsel kaygılar doğrultusunda belirlenebileceği gibi, günlük hayattaki sorunları çözümüne yönelik olarak da belirlenebilir. Finansal başarısızlığın öngörülmesi gibi bir bilimsel araştırma; işletmelerin başarısızlığa düşmelerinin altında yatan nedenleri ortaya çıkardığı kadar, işletmelerin başarısızlıklarını öngörerek başta yatırımcılar, kredi verenler, devlet, denetçiler, düzenleyici görevler üstlenen kuruluşlar ve doğal olarak yöneticilere gerekli önlemlerin alınmasını sağlayarak önemli yararlar sağlayacaktır. Bu durumda finansal başarısızlığın öngörülmesinin önemi, bu öngörülerden yarar sağlayanlar açısından incelenebilir.

2.3.1. Yatırımcılar Açısından Önemi

Genellikle güvenilir yatırımlar göreceli olarak düşük, riskli yatırımlar ise yüksek kazanç getirirler. Ancak riskli yatırım alanlarının, yatırımın kaybedilmesi olasılığını da taşıdığı diğer bir gerçektir. Yatırımcılar hangi yatırım alanlarının riskli, hangi yatırım alanlarının risksiz olduğunu bildiklerinde elde edecekleri getirileri karşılaştırarak, en uygun alternatifi seçme olanakları olacaktır. Ayrıca yatırımın hiç geri dönmeyeceği belirlenen alanlara boşuna yatırım yaparak kaynakların israf edilmesi de önlenmiş olacaktır. Özellikle sermaye piyasasında hisse senedi ve tahviller yoluyla işletmelere yatırım yapan yatırımcıların, işletmelerin gelecekteki finansal başarısızlık riskini önceden görmeleri onlara değişik yatırım stratejileri geliştirmelerinde oldukça önemli rol oynayacaktır. Örneğin gelecekte herhangi bir finansal başarısızlık yaşamayacağı öngörülen, ancak bir finansal zorluk döneminden geçen

işletmelere ait hisse senetlerinin, fiyatların düşüş yaptığı dönemde alınabilir ve işletme finansal zorluğu aştıktan sonra yüksek fiyattan satarak, yüksek oranda kar sağlanabilir.

Yatırımcılar finansal başarısızlık riskini görmede, finansal başarısızlık modellerinden yararlanırlar. Bu modellerin olmadığı durumda, yatırımcılar kararlarını sezgilerine göre vermek zorunda kalacaklardır. Sezgilere dayalı olarak karar verme, kararların doğruluk oranını azaltacağından, işletme riskine ek olarak bir de karar riski ortaya çıkacaktır. Sezgilere dayalı olarak alınan yatırım kararlarının doğruluk oranı azaldıkça , yatırımların toplam getirisi de azalacaktır. Yüksek öngörü doğruluğuna sahip bir model kullanılmasıyla kararların doğruluk oranını arttırmak da mümkün olacaktır.

2.3.2. Kredi Verenler Açısından Önemi

Kredi verenler açısından kredinin geri dönüp dönmeyeceği ayrıca kredinin faizinin ödenip ödenemeyeceği, özellikle işi kredi vermek olan bankalar açısından oldukça önemlidir. Bankaların kredi verdikleri işletmeleri risk açısından değerlendirmeleri onlar için hayati bir önem taşımaktadır. Bu nedenle finansal başarısızlık riskinin önceden bilinmesi kredi verdikleri işletmeleri seçmede büyük kolaylık sağlayacaktır.

Kredi verenler hangi kredi başvurularına kredi olanağı tanyacaklarını, hangilerine tanımayacaklarını karar vermede yüksek öngörü başarısına sahip bir model kullanarak belirleyebilirler. Model tarafından finansal başarısızlığa uğrayacağı öngörülen işletmelerin kredi talepleri geri çevrilmesi söz konusu olurken, model tarafından finansal başarısızlık grubuna dahil edilmeyen işletmeler, insan uzmanlar tarafından daha detaylı şekilde incelenerek değerlendirilebilir. Bu şekildeki bir eleme kredi veren kuruluşlarca istihdam edilen uzman sayısından tasarruf sağlayacağı gibi, uzmanların daha az sayıda kredi talebini

değerlendirmeleri sonucu, verdikleri kararların öngörü başarısı artacaktır.

2.3.3. Devlet Açısından Önemi

Devletin serbest pazar ekonomisi içindeki görevi makro bir düzenleyici olmaktır. Devlet ülke ekonomisinde ulusal gelirin kaynağı olan işletmelerin evreni ve bu evrenin gelecekteki durumu hakkında bilgiler elde etmesi, ona pazarın düzenlenmesi için karar vermede yardımcı olacaktır. Finansal başarısızlığın öngörülmesiyle, ülke ekonomisini oluşturan işletmelerin geleceği hakkında öngörüler yapmak olanaklı olacaktır.¹⁷

Örneğin devlet herhangi bir ekonomik kriz döneminde sıkı politikası izlendiğinde, bundan hangi işletmelerin olumsuz şekilde etkileneceğini bilmek için finansal başarısızlık modellerinden yararlanabilir. Hangi işletmelerin sıkı para politikasından etkileneceği bilindiğinde, devlet bu işletmelere yönelik çeşitli önlemler alabilir. Ayrıca gelecekte finansal başarısızlık sonucu kaybedeceği vergi mükellefi sayısının da, bu modeller kullanılarak öngörülmesi, toplam vergi tahsilatının ulaşacağı rakamı belirlemede yararı olacaktır. Bu tür modeller kullanarak öngörülerde bulunmayan devlet organlarının alacakları kararların, günü birlik kararlar olacağı açıktır.

2.3.4. Düzenleyici Kuruluşlar Açısından Önemi

Bankalar, sigorta şirketleri gibi işletmeler büyük yatırımları gerektirdiğinden ve toplumun çok geniş kesimlerini ilgilendirdiklerinden bazı düzenleyici kuruluşlar tarafından

¹⁷ FOSTER George, *Financial Statement Analysis*, Second Ed. Prentice Hall International Inc., New Jersey, 1986, pp.534-535

izlenmekte ve gerekirse olumsuz gelişmeleri önleyici tedbirler, bu düzenleyici kuruluşlar tarafından alınmaktadır. Bu düzenleyici kuruluşlara Sermaye Piyasası Kurulu, mevduat güvence fonu, merkez bankaları örnek gösterilebilir. Finansal başarısızlığın öngörülmesi söz konusu düzenleyici kuruluşların izleme ve kontrol etkilerini arttırıcı bir etki yapacağından, finansal başarısızlığın öngörülmesi bu tür kuruluşlar içinde oldukça yararlı olacaktır.¹⁸ Bu nedenle düzenleyici işlevi olan kuruluşların finansal başarısızlığın öngörülmesinde kullanılacak modellere oldukça fazla gereksinimleri vardır. Bu tür modelleri kullanan düzenleyici kuruluşlar, finansal başarısızlığa uğrama olasılığına sahip kuruluşları kontrol altına alarak, toplumu geniş ölçüde etkileyecek olumsuz gelişmelerin önüne geçebilirler.

Örneğin ülkemizde, bankerlerin ve bazı bankaların finansal başarısızlık durumları önceden öngörülebilseydi, bunlar kontrol altına alınarak, topluma ekonomik alandaki olumsuz etkileri önlenebilirdir.

2.3.5.Bağımsız Denetçiler Açısından Önemi

Genellikle finansal zorluk içinde bulunan işletmelere ait finansal tablolarının daha fazla hata ve makyaj içermesi riski bulunmaktadır. Bunun anlamı daha yüksek kontrol ve bulgu riski demektir. Finansal başarısızlığın öngörülmesi bağımsız denetçilere inceledikleri işletmenin finansal durumu ve dolayısıyla, denetim riski hakkında daha fazla bilgi sağlayacaktır. Böylelikle denetçi müşteri işletmeyi seçme aşamasında veya görüşünde daha doğru sonuçlara ulaşmış olacaktır.

Denetçiler denetim yaptıkları işletmenin finansal başarısızlık potansiyeli taşıyıp

¹⁸ A.g.e.

taşımadıklarını bir model aracılığıyla öngörebildiklerinde, bağımsız denetim için başvuran işletmelerin değerlendirilmesi ve denetimin planlanması hızlanacak ve kolaylaşacaktır.

2.3.6. İşletme Yöneticileri Açısından Önemi

Bir başarısız işletmede yöneticilerin başarısızlığı son ana kadar kabullenemedikleri veya tespit edemedikleri yapılan araştırmalardan bilinmektedir.¹⁹ Finansal başarısızlığın öngörülmesi, yöneticiye işletmesinin durumu hakkında tarafsız ve gerçekçi bilgi sağlaması, ayrıca iş ilişkisi içinde bulunduğu işletmeler hakkında daha doğru kararlar vermesi açısından önemli katkı sağlayacaktır. Yöneticiler işletmelerinin durumunu finansal başarısızlığı öngören bir model aracılığıyla analiz ettiklerinde, modelin vereceği erken uyarı, yöneticinin durumunu daha objektif ve daha detaylı değerlendirmesi için bir fırsat yaratacaktır. İşletme yöneticileri bu tip bir değerlendirmeyi kredili mal sattığı işletmelere de uygulayarak, kredili satış politikasını belirleyebilir.

Finansal başarısızlığın öngörülmesinde kullanılan bir model, işletme yöneticilerine yeni ortaklıklar veya yeni birleşmeler için uygun adayların belirlenmesinde de oldukça yardımcı olacaktır. Model aracılığıyla güçlü şirketlerle ortak yapılması mümkün olur. Ayrıca, yöneticiler model aracılığıyla finansal zorluk durumunda olduğunu belirlediği işletmeleri, daha az sermaye kullanarak satın alabilir.

¹⁹ BARTOL Kathryn M.-MARTIN Davit C., *Management*, McGraw-Hill Inc., New York,1991, pp.223-224.



ÜÇÜNCÜ BÖLÜM

FİNANSAL BAŞARISIZLIĞIN ÖNGÖRÜLMESİ

ÜÇÜNCÜ BÖLÜM

FİNANSAL BAŞARISIZLIĞIN ÖNGÖRÜLMESİ

3.1.FİNANSAL BAŞARISIZLIĞIN ÖNGÖRÜLMESİNDE KULLANILANILAN MODELLER

Yapılan yazın taramasında finansal başarısızlığın öngörülmesine yönelik olarak çok değişik model denemeleriyle karşılaşılmıştır. Bu model denemelerinin başında matematiksel istatistiksel tekniklere dayalı olan modeller gelmektedir. Yazında insan sezgisine dayalı teknikleri incelemek amacıyla, insan öngörülerinin başarısını matematiksel- istatistik tekniklerin başarısıyla karşılaştıran çalışmalar da bulunmaktadır. Finansal başarısızlığın öngörülmesinde uzman sistem ve yapay sinir ağları olarak adlandırılan yapay zeka teknolojilerine dayalı model denemeleri de son zamanlarda bilgiişlem teknolojisindeki gelişmelere paralel olarak artmaktadır. Yukarıda sözü edilen bu modellerde değişken olarak çoğunlukla finansal oranlar, nakit akımı, fon akımı gibi işletmeye ait muhasebe bilgileri veya piyasa verileri kullanılmıştır.

3.1.1. Matematiksel – İstatistiksel Modeller

Finansal başarısızlığı öngörme konusunda yapılan çalışmalarda kullanılan matematiksel-istatistiksel modeller üç grupta sınıflandırılabilir:¹

- i. Tek değişkenli modeller
- ii. Çok değişkenli modeller
- iii. Parametrik olmayan modeller.

Tek değişkenli modellerde, finansal başarısızlık tek bir değişkene bağlı olarak öngörülme çalışılır. Bu değişkenin aldığı değer bir kopuş noktasıyla karşılaştırılır ve işletmenin finansal başarısız veya finansal başarısız olmayan gruplarından hangisine atanacağına karar verilir. Birden fazla değişkenin incelendiği bazı çalışmalarda da, değişkenler tek tek ele alındıkları için tek değişkenli model denemeleri içinde incelenmelidirler.

Çok değişkenli modellerde finansal başarısızlığı belirleyen bağımlı değişken, birden fazla bağımsız değişkenin aldığı değere göre belirlenir. Bu bağımlı değişkenin ulaştığı değer bir kopuş noktasıyla karşılaştırılarak, işletmenin hangi gruba atanacağına karar verilir.

Çok boyutlu modeller içinde özellikle Çok Boyutlu Ayırma Analizi (Multivariate

¹ FOSTER George, *Financial Statement Analysis*, Second Ed. Prentice Hall International Inc., New Jersey, 1986, pp. 546-547.

* Kopuş noktası, istatistiksel anlamda grup üyelerinin birbirinden ayıran sınır değerdir.

Discriminant Analysis)², Çoklu Regresyon Analizi (Multivariate Regrassion Analysis), Logit (Logistic Regrassion Analysis), Probit Analizi, parametrik olmayan modellerden ise Döngüsel Bölümleme Analizi (Recursive Partitioning Analysis) sıklıkla kullanılan ve göreceli olarak daha başarılı modellerin geliştirilmesine olanak tanıyan tekniklerdir. Aşağıda bu tekniklerden yararlanan model denemeleri, örneklem ve ulaştıkları sonuçlar bakımından özetlenmeye çalışılmıştır. Her bir matematik ve istatistik tekniğin kullanıldığı modellere nasıl ulaşıldığının ayrıntılı açıklanmasına, çalışmanın sınırlarını gereğinden fazla genişleteceği için yer verilmemiştir.³

3.1.1.1. Tek Değişkenli Modeller

Finansal başarısızlık yazınında en eski çalışma, 1923-1931 yılları arasında faaliyet göstermiş ve 1931 yılında başarısız olmuş 133 işletmenin finansal tablolarına dayalı olarak yapılmış olan çalışmadır.⁴ Daha sonra M. Tamari⁵ tarafından yapılan bir başka çalışma bulunmasına rağmen, William H. Beaver tarafından yapılan üç çalışma yazında en çok başvuru yapılan çalışmalar olması bakımından, matematik-istatistik teknikler kullanan çalışmalar içinde, özel önem taşımaktadır.

Beaver ilk çalışmasında, finansal başarısızlığı öngörmede finansal oranların gücünü

² Çok boyutlu ayırma analizinin doğrusal (linear) ve kuadratik (quadratic- karesel formda) olmak üzere iki şekli bulunmaktadır. Ancak çalışmanın bundan sonraki bölümlerinde modelin doğrusal ve kuadratik olması önem taşımadığı sürece ifade kolaylığı sağlamak amacıyla sadece "Ayırma Analizi" olarak anılacaktır.

³ Ayrıca Bkz: TATLI Hüseyin, **Çok Değişkenli İstatistiksel Analiz**, Ankara, 1991.; KURTULUŞ Kemal, **Pazarlama Araştırmaları**, Beşinci Baskı, İ.Ü. İşletme Fakültesi Yayın No :28, İstanbul, 1996; MARCOULIDES George A. - HERSHBERGER Acott L., **Multivarite Statistical Methods : A First Course**, Lawrence Erlbaum Associates, Publishers, New Jersey, 1997.

⁴ ALTMAN Edward I. , **The Prediction of Corporate Bankruptcy: A Discriminant Analysis**, Garland Publishing, Inc., New York, 1988, p.15.

⁵ TAMARI M., " Les Ratios, Moyen de Prévision des Faillites", **Management International Review**, V.:IV, (1968), pp.22-27.

ölçmüş ve finansal oranları işletme başarısızlığının öngörülmesinde kullanılabileceği sonucuna varmıştır. Endüstriler arası farklılıkların ve işletme büyüklüğünün oranlar üzerindeki etkisinin arındırılması için, eşlemeli örneklem tekniğinin kullanıldığı çalışmada 79 başarısız olmayan ve 79 başarısız işletme örnekleme dahil edilmiştir. 30 oranın incelenmesi sonucunda, başarısız işletmeleri başarısız olmayan işletmelerden ayırmada önemli olduğunu saptadığı 5 oran bulmuştur. Bunlar finansal başarısızlığı öngörmedeki yeterlilikleri açısından sıralandığında :⁶

- a. Nakit Akımı / Toplam Borç
- b. Net Dönem Karı / Toplam Varlıklar
- c. Toplam Borçlar / Toplam Varlıklar
- d. Net İşletme sermayesi / Toplam Varlıklar
- e. Cari oran'dır.

Bu çalışmasından sonra aynı veri setiyle yapılan ikinci bir çalışmada işletmeleri başarısız olmayan ve başarısız ayırımında hatayı minimize edecek şekilde, her oran için başarısız olmayan işletmeleri başarısız işletmelerden ayıran bir kopuş değeri hesaplamıştır.

İkinci çalışmada, yukarıda yer alan varlıklar ile toplam borç rakamlarına dayalı ilk üç oranın finansal başarısızlığı 5 yıl öncesine kadar oldukça az bir hatayla öngördüğü anlaşılmıştır. Ayrıca aynı çalışmada, başarısız olmayan ve başarısız işletmeler için ayrı - ayrı

⁶ BEAVER William H., "Financial Ratios as Predictors of Failure", *Empirical Research in Accounting: Selected Studies*, 1966, *Journal of Accounting Research*, [1967], pp.71-111'den naklen; FOSTER, A.g.e.,s.542.

ortalama deęerler hesaplanarak, bunlar karřılařtırılmıřtır.⁷

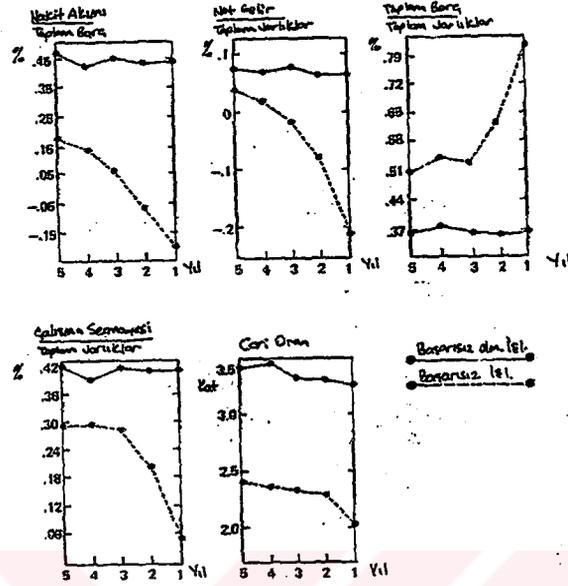
Finansal oranlar ile sermaye piyasasının verilerinin finansal başarısızlıęı öngörmedeki yeterliliklerinin ve aralarındaki iliřkinin arařtırıldıęı Beaver'a ait üçüncü çalıřma da, ilk ve ikinci çalıřmalarında kullandıęı örnekleme dayalıdır. Bir finansal oran ile piyasa verilerinin, en az hatayla sınıflandırmaya olanak veren kopma noktaları tespit edildikten sonra, finansal oranın piyasa verilerine göre finansal başarısızlıęı daha az hatayla öngördüęü, ancak piyasa verileri ile oranlar arasında tam bir iliřkinin de olmadıęı sonucuna varılmıřtır.⁸

Beaver' in finansal başarısızlıktan 5 yıl öncesi için, başarısız iřletmeler ve başarısız olmayan iřletmeler için hesaplanan ortalamaları Őekil 3.1 'deki gibidir. Özellikle Nakit Akıřı / Toplam Borç oranının finansal başarısızlıktan 5 yıl öncesinde önemli derecede farklı davranıř sergiledięi görölmektedir.

⁷ BEAVER William H., "Alternative Accounting Measures As Predictors of Failure", **The Accounting Review**, V:42 N:1 (January 1968), pp.113-122.

⁸ BEAVER William H., "Market Prices, Financial Ratios, and the Prediction of Failure", **Journal of Accounting Research**, (Autumn,1968), pp.179-192.

Şekil 3. 1 : Beaver'in çalışmasında elde ettiği kopuş noktaları



Kaynak: BEAVER William H., "Financial Ratios as Predictors of Failure", *Empricial Research in Accounting: Selected Studies*, 1966, *Journal of Accounting Research*, [1967], p.82'den naklen FOSTER George, *Financial Statement Analysis*, Second Ed. Prentice Hall International Inc., New Jersey, 1986, p.543.

3.1.1.2. Çok Değişkenli Modeller

Yazında çok değişkenli model denemelerinin sayısı oldukça fazladır. Bu model denemelerinde, en uygun modelin bulunması süreci birkaç istatistiksel tekniğin karşılaştırılmasını gerektirmiştir. Bu nedenle çalışmaların, kullanılan istatistik tekniği temel alınarak sınıflandırılması sorun yaratmaktadır. Ancak söz konusu çalışmalarda bağımsız değişken olarak kullanılan bilgiler araştırma boyunca değiştirilmemeleri nedeniyle, çok değişkenli çalışmaları incelemede, kullanılan değişkenleri temel alan bir sınıflandırma yaklaşımı izlenecektir.

3.1.1.2.1. Finansal Oranların Değişken Olarak Kullanıldığı Modeller

Finansal başarısızlık yazınına bir çok çalışmayla önemli katkıda bulunan Edward I. Altman'a ait bir çalışma, çok değişkenli model öneren ilk çalışma olması bakımından önem taşımaktadır. Altman, finansal başarısızlığı öngörmeye yönelik yorumlamalara neden olabileceği gerekçesiyle, tek değişkenli modellerin finansal oranları tek tek dikkate almalarını eleştirmiştir. Buna göre, bir işletmenin finansal oranlarından bazılarının gösterdiği trende veya performansa bakılarak, işletmenin finansal başarısızlık potansiyeli taşıdığını söylemek her zaman için doğru olmayacak bir yorumlamadır. Çünkü işletmenin bazı finansal oranları kötü bir trend veya performans sergilerken, diğer finansal oranları oldukça iyi durumda olabilir ve işletme gerçekte finansal başarısızlık potansiyeli taşımadığı halde, finansal başarısızlık riski bulunduğu sonucuna varılabilir. Aslında bu eksikliğin modelin tek boyutlu olmasından kaynaklandığını öne süren Altman, bu sorunu ortadan kaldırmak amacıyla 33 başarısız olmayan ve 33 başarısız işletmeden oluşan örnekleme çok boyutlu bir model geliştirmeye çalışmıştır.⁹

Altman çalışmasında ilk olarak, likidite, karlılık, finansal kaldıraç, ödeme gücü ve faaliyet şeklinde 5 grupta, toplam 22 finansal oran tespit etmiştir. Ancak çalışma sırasında istatistik tekniğin yardımıyla, her bağımsız değişkenin açıklama gücü, değişkenler arasındaki karşılıklı ilişkiler, bağımsız değişkenlerin modelin doğruluğuna olan katkıları ve son olarak da analistin yargıları dikkate alınarak bu değişken sayısı 5'e indirilmiştir. Modelin bağımsız

⁹ ALTMAN Edward I., "Financial Ratios, Discriminant Analysis and The Prediction of Corporate Bankruptcy", *The Journal of Finance*, V: XXIII, N:4 (September, 1968), pp.589-609.

değişkenleri (X_i) olan bu finansal oranlar şu şekilde sıralanmıştır. ¹⁰

$$X_1 = \text{Çalışma Sermayesi} / \text{Toplam Varlıklar},$$

$$X_2 = \text{Dağıtılmamış Karlar} / \text{Toplam Varlıklar},$$

$$X_3 = \text{Faiz ve Vergiden Önceki Kar} / \text{Toplam Varlıklar},$$

$$X_4 = \text{Özsermaye} / \text{Toplam Borç}, ¹¹$$

$$X_5 = \text{Satışlar} / \text{Toplam Varlıklar}.$$

Altman'nın ayırma analizi sonucu bulduğu fonksiyon aşağıdaki gibidir: ¹²

$$Z = 0,012X_1 + 0,014X_2 + 0,033X_3 + 0,006X_4 + 0,999X_5$$

Burada Z ayırma skorunu göstermektedir.

Fonksiyon başarısız işletmeleri % 94, başarısız olmayan işletmeleri % 97 ve toplamda % 95 doğrulukla sınıflandırmıştır. Söz konusu modelin performansı finansal başarısızlıktan iki yıl öncesi için % 72, üç yıl öncesi için % 48, dördüncü ve beşinci yıllar için ise % 29 ve %39'dur. ¹³ Bu çalışmada başarısız ve başarısız olmayan işletmelerin bu beş oran için hesaplanan ortalamaları Tablo 3.1'deki gibidir.

¹⁰ A.g.e.

¹¹ Bu oran A.B.D.'de işletmenin özsermayesinin hisse senetlerinin piyasa değerlerinin toplamıyla hesaplanmasından dolayı aslında İşletmenin Piyasa Değeri / Toplam Borç şeklindedir. AKGÜÇ, A.g.e., s.85-86.

¹² ALTMAN, "Financial Ratios,.." p. 594.

¹³ A.g.e.,p.604.

Tablo 3. 1 :Başarısız ve Başarısız Olmayan İşletmelerin Ortalamaları ve F Değerleri

| Değişken | Başarısız İşletmelerin Ortalamaları | Başarısız Olmayan İşletmelerin Ortalamaları | F Değeri |
|----------------|-------------------------------------|---|----------|
| | n=33 | n=33 | |
| X ₁ | %-6,1 | %41,4 | 36,60* |
| X ₂ | %-62,6 | %35,5 | 58,86* |
| X ₃ | %31,8 | %15,3 | 26,56* |
| X ₄ | %40,1 | %247,7 | 33,26* |
| X ₅ | %150 | %190 | 2,84* |

* 0,001 Anlamlılık düzeyinde

Kaynak : Altman Edward I., "Financial Ratios, Discriminant Analysis and The Prediction of Corporate Bankruptcy", *The Journal of Finance*, C: XXIII, N:4 (September, 1968), p.596.

Bu tablodan da anlaşılacağı gibi X₅ değeri haricinde tüm değişkenler her iki grup içinde farklı ortalama değerler (0,001 anlamlılık düzeyinde) ortaya koymuşlardır.

Altman, geliştirmiş olduğu modeli ikinci bir örneklem üzerinde uygulayarak geçerliliğini test etmiş ve sonuçta % 96 oranında başarılı olduğunu görmüştür.¹⁴

Altman, yukarıda özetlenen ilk çalışmasında doğrusal ayırma analizini kullanmıştır. Ancak daha sonraki çalışmasında, sapma matrislerinin eşitliğinin gerçekleşmemesine bağlı olarak kuadratik ayırma analizini kullanılmasının daha uygun olacağı belirtilmiş* ve, doğrusal ayırma analizi tekniği yerine kuadratik ayırma analiziyle yeni bir model daha geliştirmiştir.¹⁵

¹⁴ ALTMAN, "Financial Ratios,....",p.601.

* Kuadratik ayırma analizi, doğrusal ayırma analizinin varsayımlarından biri olan sapma matrislerinin eşitliğine, değişkenlerin çoklu normal dağılım göstermesi koşulu ile gereksinim duymaz.

¹⁵ ALTMAN Edward I.- LORRIS Bettina, " A Financial Early Warning System for Over-the-Counter Broker-dealers, *The Journal of Finance*, V:XXXI N:4 (September 1976), pp.1201-1217.

Kuadratik ayırma analizinin kullanıldığı modelde, 40 başarısız ve 113 başarılı olmayan işletme örnekleme dahil edilmiştir ve önceki çalışmadan farklı olarak şu finansal oranlar değişken olarak kullanılmıştır: ¹⁶

- i. Vergiden Sonraki Net Kar / Toplam Varlıklar,
- ii. (Pasif Toplamı + Teminatlar) / Öz Sermaye,
- iii. Toplam Varlıklar / Düzeltilmiş Net Sermaye,
- iv. (Son Sermaye – Sermaye Eklmeleri) / Başlangıç Sermaye,
- v. Ölçeklendirilmiş Yaş, **
- vi. Bileşik Değişken (On değişkenin bileşkesidir).

Bu model başarısız olmayan işletmeleri %90,3 ve başarısız işletmeleri %90 oranında doğru sınıflandırmıştır. Bu ifadeye ek olarak, daha önce kullanmış olduğu doğrusal ayırma analizinin ve kuadrantik ayırma analizinin grupları ayırmada doğruluk açısından önemli fark yaratmadığı da belirtilmiştir. ¹⁷

Altman bu modeli daha da geliştirerek, ZETA CREDIT RISK SCORE adıyla ticari bir uygulama haline getirmiştir. ZETA modeli işletmeleri finansal açıdan başarısız ve başarılı olmayan şeklinde öngörmek yerine, daha önce başarısız olmuş 53 işletme ile 58 başarılı

¹⁶ A.g.e.,p.1203.

^{**} İşletme yaşı ve işletme riski arasında bir ilişki vardır. Deneyimden kaynaklanan bu ilişki temel alınarak şu ölçek geliştirilmiştir : 0-1 yaş için 2.5; 1-2 yaş için 5.7; 2-3 yaş için 4.5; 3-4 yaş için 6.7; 4-5 yaş için 5; 5-10 yaş için 1.2; 10 yaş ve üstü için 3 ölçeklendirilmiş yaş kullanılmıştır.

¹⁷ A.g.e.

olmayan işletmeyi, finansal ve faaliyet karakteristikleri açısından karşılaştırır. Sonuçta, işletmenin kredibilite açısından iyi veya kötü olduğuna ilişkin bir derece elde edilir. Ticari bir uygulama olması nedeniyle katsayıları açıklanmayan modelde kullanılan değişkenler şunlardır:¹⁸

- i. Varlıklar üzerinden getiri,
- ii. Karlılığın istikrarı,
- iii. Faizi karşılama oranı,
- iv. Kümülatif karlılık,
- v. Likidite,
- vi. Özsermayenin toplam varlıklara oranı,
- vii. İşletme büyüklüğü.

Kullanılan veriler açısından kuadratik ayırma analizinin daha uygun olduğu belirtilmekle beraber; yapılan karşılaştırmada doğrusal ayırma analizinin daha iyi öngörülerde bulunduğu için, doğrusal ayırma analizinde karar kılınmıştır.¹⁹

1970'lerden sonra 150'den fazla finansal başarısızlığı öngören ZETA analizinin değişik dönemlerdeki performansı Tablo 3.2'deki gibidir.

¹⁸ ALTMAN Edward I., *Corporate Financial Distress and Bankruptcy: A Complete Guide to Predicting and Avoiding Distress and Profiting from Bankruptcy*, Second Ed., John Wiley and Sons, Inc., New York, 1993, pp.208-214.

¹⁹ A.g.e., pp. 214-217.

Tablo 3. 2 :ZETA analizinin deęişik sürelerdeki performansı

| Finansal Başarısızlıktan Önceki Yıl | 17 Yıllık Sürede 1974-1991 | 5 Yıllık Sürede 1987-1991 | Orijinal Örnekleme 1962-1975 |
|-------------------------------------|----------------------------|---------------------------|------------------------------|
| 1 | 94 | 95 | 96 |
| 2 | 86 | 87 | 85 |
| 3 | 74 | 75 | 75 |
| 4 | 66 | 68 | 68 |
| 5 | 64 | 64 | 70 |

Kaynak: ALTMAN Edward I., **Corporate Financial Distress and Bankruptcy: A Complete Guide to Predicting and Avoiding Distress and Profiting from Bankruptcy**, Second Ed., John Wiley and Sons, Inc., New York, 1993, p.220.

Deakin tarafından yapılan bir çalışma, Beaver ve Altman tarafından yapılan araştırmaların bir tekrarı ve karşılaştırması niteliğindedir. Bu karşılaştırmada, finansal başarısızlıktan bir yıl öncesi Altman' ın, ancak finansal başarısızlıktan 2-5 yıl öncesi için de Beaver' in modelinin daha başarılı olduğunu vurgulamıştır.²⁰

Deakin, öncelikle Beaver'in modelini kendisinin 1964-1970 yılları arasındaki dönemden seçtiği 32 birimlik örneklem üzerinde tekrarlamıştır. 14 finansal oran için, finansal başarısızlıktan 1-5 yıl öncesinde kendi yaptığı çalışmada ulaştığı hata oranları ile Beaver' in ulaştığı hata oranlarını karşılaştırdığında, yıllar bazında modelin doğru sınıflandırma oranlarında farklılıklar gözlemlemiş, fakat her iki modelin doğru sınıflandırma oranlarının genel olarak yüksek bir korelasyon içerdiği sonucuna varmıştır. Sonrasında kendi çalışması ile Beaver'in çalışması arasındaki bu farklıları kendi yorumlarıyla açıklamaya çalışan Deakin,

²⁰ DEAKIN Edward B., "A Discriminant Analysis of Predictors of Business Failure" **Journal of Accounting Research**, V:10 N:1 (Spring 1972), pp.167-168.

genel olarak doğru sınıflayan bu modelden ilk yıl için %20 daha iyi öngörüde bulunan ayırma analizine geçmiştir.²¹

Ayırma analizinde, ilk modelde kullandığı 14 oranı kullanmış ancak işletmelerin finansal açıdan başarısız- başarısız olmayan gruplara olan üyeliklerini belirlemede en yüksek doğru sınıflandırma oranını sağlayacak bir kopuş noktası seçerek, ilk yıl için %13, önceki 2-3 yıl için ise %10 ve %18 hatayla finansal başarısızlıkları öngörmüştür. Finansal başarısızlıktan önceki 1., 2. ve 3. yıllar için Beaver ve Altman'dan daha tutarlı sonuçlara ulaşan Deakin; 4. ve 5. yıllar için bu iki çalışmadan daha fazla hata oranıyla karşılaşmıştır. Bu çalışmanın 11 başarısız ve 23 başarısız olmayan işletme üzerinde yapılan geçerlilik testinde özellikle ilk yıl için (%23) hata oranıyla önemli bozulma görülmüştür.²²

1980 yılındaki James A. Ohlson'un çalışmasında, öncelikle yapılmış olan çalışmalar veri toplama ve kullanılan istatistiksel teknikler açısından eleştirilmiştir. Ohlson bir olayı öngörmeye kullanılmak üzere değişkenlere ait verilerin olayın gerçekleşmesinden önceki dönemde toplanması gerektiğine dikkat çekerek, önceki araştırmalarda bu konuya dikkat edilmediğini belirtmektedir. İkinci eleştiri ise kullanılan çoklu ayırma analizinin varsayımlarının gerçekleşmediği şeklindedir.²³ Ohlson'un, finansal başarısızlığı öngörmeye kullanılan istatistiksel tekniklere ilişkin eleştirileri ve karşılaşılan sorunlar, çalışmanın ileri ki bölümlerinde ayrıntılı olarak değerlendirileceğinden, burada tekrar edilmeyecektir.

²¹ A.g.e., pp. 169-171.

²² A.g.e., pp. 172-178.

²³ OHLSON James A., "Financial Ratios and Probabilistic Prediction of Bankruptcy", *Journal of Accounting Research*, V:18 N:1 (Spring 1980), pp.109-131.

Ohlson, çok deęişkenli ayırma analizinin yarattığı problemlerden kaçınmak için Lojistik Regresyon (Logit olarak da bilinmektedir) tekniğini kullanmıştır. Finansal açıdan başarısız 105 ve finansal başarısızlık olmayan 2058 işletmeye ait verilerin bulunduğu oldukça büyük örneklem kümesi, 1970-1976 dönemleri arasında sermaye piyasasında veya ikincil piyasada işlem gören, ayrıca bir endüstri kolunda sınıflandırılmış işletmelerden oluşturulmuştur. Finansal başarısızlığı yasal kriterlere dayandırarak, sadece iflas etmiş veya bu konuda yasal işlem görmüş işletmeler örnekleme dahil etmiştir. Örnekleme girecek işletmeler için oldukça sıkı bir eleme yapıldığı çalışmada; küçük ve kişisel işletmeler, taşımacılık, finans, sigorta sektörüne giren işletmeler, finansal başarısızlıktan üç yıl önceki finansal tabloları elde edilemeyen işletmeler ile satışı çok az veya hiç olmayan işletmeler örneklem dışı bırakılmıştır. Örneklemdaki işletmelerin finansal tabloları, finansal başarısızlıktan 3 - 33.5 ay önceki dönemlere aittir ve ortalama olarak 13 ay önce açıklanmıştır.²⁴

Logit tekniği kullanılarak iflastan 1 yıl öncesi için Model 1, iflastan 2 yıl öncesi için Model 2 ve iflastan önceki 1-2 yılı kapsayan Model 3 adlı modeller geliştirilmiştir. Bu modeller aşağıdaki oranları deęişken olarak kullanmaktadır.²⁵

- i. İşletme büyüklüğü,
- ii. Toplam yükümlülük / Toplam varlıklar,
- iii. Çalışma sermayesi / Toplam varlıklar,
- iv. Cari borçlar / Cari varlıklar,

²⁴ A.g.e., p.114.

²⁵ A.g.e., pp.118-120.

- v. Toplam borçların toplam varlıkları aştığı durumda 1, aksi durumda 0 değeri alan değişken,
- vi. Net kar / Toplam varlıklar,
- vii. Faaliyetlerden elde edilen fonlar / Toplam borçlar,
- viii. Son iki yıldaki net kar negatif olduğunda 1, aksi durumda 0 değeri alan değişken,
- ix. $(NK_t - NK_{t-1}) / (|NK_t| + |NK_{t-1}|)$ burada NK_t son döneme ait net karı ifade etmektedir. Bu oran işletmenin net kar rakamındaki değişmeyi ölçmeyi amaçlamaktadır (t =zaman).

İlk modelin % 96,12, ikinci modelin % 95,55 ve üçüncü modelin % 92,84 oranında başarıyla sınıflandırma yaptığı çalışmada, üçüncü, dördüncü ve sekizinci değişkenler dışındaki değişkenler önemli bulunmuştur. Bunlar işletme büyüklüğü, finansal yapıyı yansıtan toplam borç / toplam varlıklar, işletme performansını yansıtan net kar / toplam varlıklar veya faaliyetlerden elde edilen fon / toplam borç, likidite ölçütleri olan çalışma sermayesi / toplam varlıklar veya çalışma sermayesi / toplam varlık ile cari borç / cari varlıklar birlikteliğidir.²⁶

3.1.1.2.2. Finansal Oranlardaki İstikrarı Değişken Olarak Kullanan Modeller

İşletmeye ait finansal oranların finansal başarısızlık yaklaştıkça daha büyük dalgalanmalar gösterdiği bilinmektedir. Bundan dolayı finansal oranlardan oluşan verilerdeki istikrarı inceleyerek, verilerdeki istikrarın etkilerini ayırma analizine katan çalışmalar da

²⁶ A.g.e., pp.120-123.

yapılmıştır. Bunlardan birinde finansal oranlardaki istikrarı ölçmede kullanılan üç ölçü şunlardır:²⁷

- i. Finansal oranların finansal başarısızlıktan önceki yıllarda gösterdikleri standart sapma,
- ii. Öngörünün standart hatası,
- iii. Finansal başarısızlığa uğramış işletmelerle finansal başarısızlığa uğramamış işletmelerin karşılaştırılmasındaki kovaryans katsayıları.

Örnekleme alınan 1969-1975 dönemine ait 46 işletmeye ait sekiz yıllık verilerden, işletmelerin başarısızlığa yaklaştıkça finansal oranlardaki istikrarsızlığın arttığı gözlemlenmiştir.²⁸

Finansal oranlardaki istikrarsızlığın ayırma analizine olan etkisinin ölçülmesi için, öncelikle 1, 3 ve 5 yıl öncesi için sadece finansal oranları kullanan doğrusal ayırma fonksiyonları geliştirilmiştir. Daha sonra ikinci bir modelde standart sapma, ayırma analizine dahil edilmiştir. Sonuçta standart sapmanın ayırma analiziyle geliştirilen modele katkısı ilk yıl için önemli oranda olmazken; 3. ve 5. yıllar için işletmeleri doğru sınıflandırmada önemli katkısı olduğu saptanmıştır.²⁹ Standart sapmanın değişken olarak kullanıldığı ve kullanılmadığı durumdaki ayırma fonksiyonunun öngörü başarısı Tablo 3.3’de özetlenmiştir.

²⁷ DAMBOLENA Ismael G.- KHOURY Sarkis J.,” Ratio Stability and Corporate Failure”, *The Journal Of Finance*, V:XXXV N:4 (September 1980), pp. 1017-1026.

²⁸ A.g.e., pp.1017-1020.

²⁹ A.g.e., pp.1022-1025.

Tablo 3. 3: Standart sapmanın ayırma fonksiyonun başarısına etkisi

| Kullanılan Değişkenler | Başarısızlıktan Önceki Yıl Sayısı | Doğru Sınıflandırma Oranı % | | Toplam |
|---------------------------------------|-----------------------------------|-----------------------------|-------------------|--------|
| | | Başarısız | Başarısız olmayan | |
| Sadece Finansal Oranlar | 1 | 89 | 100 | 94,4 |
| | 3 | 81 | 78 | 79,7 |
| | 5 | 66 | 75 | 70,3 |
| Finansal oranlar ve standart sapmalar | 1 | 91 | 100 | 95,7 |
| | 3 | 87 | 91 | 89,1 |
| | 5 | 78 | 87 | 82,6 |

Kaynak: DAMBOLENA Ismael G.- KHOURY Sarkis J.,” Ratio Stability and Corporate Failure”, *The Journal Of Finance*, V:XXXV N:4 (September 1980), p.1023.

Finansal oranların istikrarını temsil etmek üzere üç yıl için hesaplanan standart sapmanın ayırma fonksiyonuna etkisi, 4 yıl için hesaplanan standart sapmanınikiyle aynı olurken; 4 yıllık trendde hesaplanan tahminin standart hatası ve varyasyon katsayılarının, istikrar ölçüsü olarak ayırma fonksiyonuna katılmaları, göreceli olarak daha düşük öngörü başarısı sağlamıştır.³⁰

3.1.1.2.3. Nakit ve Fon Akımına Ait Değişkenlerin Kullanıldığı Modeller

Finansal başarısızlığın öngörülmesinde, nakit veya fon akımına ilişkin değişkenlerin modellerin öngörü doğruluğunu arttırmak amacıyla kullanıldığı görülmektedir. Bu çalışmalarda çoğunlukla ayırma analizi, Probit veya Logit tekniklerinin tercih edildiği veya

³⁰ A.g.e., pp.1024.

karşılaştırma amacıyla nakit ve fon akımının etkilerinin, bu tekniklerin her üçüyle de incelendiği gözlemlenmektedir.

Beaver ve Altman tarafından yapılan çalışmaları bir teorik çerçeve sunmamalarından dolayı eleştiren Wilcox, kendisi teorik bir genellemeye varmak için “Kumarbazın İflası” modelini, işletmelerin finansal başarısızlıklarını öngörme konusuna uyarlamıştır. İşletme riskini, işletmenin net likidasyon değeri ve bu değerinde dalgalanmalara yol açan faktörlere bağlayarak, nakit giriş ve çıkışlarına ilişkin oranları kumarbazın iflası modelinde kullanmıştır. Nakit giriş oranı musluktan akan suya, nakit çıkış oranı ise tahliye borusundan boşaltılan suya benzetildiğinde; suların giriş ve çıkış hızları arasındaki farka göre havuzun içindeki su miktarı değişeceği gibi; nakit giriş ve çıkış oranları arasındaki farka göre de işletmenin net likidasyon oranı değişecektir. Buradaki nakit giriş oranı net kar eksi temettüleri, nakit çıkış oranı ise varlıkların defter değeri eksi varlıkların likidite değerindeki artıştır. Modelin amacı ise havuzdaki suyun ne zaman biteceği, diğer bir deyişle işletmenin net likidasyon değerinin ne zaman negatif olacağını öngörülmesidir. Wilcox modelinin iflasdan önceki yıllar için doğru sınıflama olasılıkları şöyledir: 1. yıl öncesi %94, 2 yıl öncesi %89, 3 yıl öncesi %89, 4 yıl öncesi %91 ve 5 yıl öncesi için %76.³¹

Logit tekniğine dayanan farklı bir çalışmada, işletmelere ait finansal durumu ifade eden 5 sınıflama yapılmıştır. Bunlar 0: finansal açıdan istikrarlı, 1: dağıtılan kar payında azalma veya kar payının hiç dağıtılmaması, 2: borçların ödenmesinde veya tahvil borçların geri ödemesinde gecikme, 3: iflas yasağının korumasına altına girmek, 4: iflas veya likidasyon.³²

³¹ ALTMAN Edward I., Corporate..., pp.232-233.

³² HING Amy- LAU Ling, “A Five State Financial Distress Prediction Model”, *Journal of Accounting Research*, V:25 N:1 (Spring 1987), pp.127-128.

Her biri 350 finansal başarısız olmayan işletme ile; sırasıyla 1., 2., 3. ve 4. durumda olan 20, 15, 10 ve 5 başarısız işletme içeren iki örneklem oluşturularak, biri modelin geliştirilmesi, diğeri geçerlilik testleri için kullanılmıştır. Çalışmada 3 Logit modeli geliştirilmiştir. İlk model 1974-1975 yılları arasındaki verilere dayalı olarak 1976 yılındaki finansal başarısızlıkları bir yıl önceden, ikinci model 1973-1974 yılları arasındaki verilere dayalı olarak iki yıl öncesinden, üçüncü model ise 1972-1973 yılları arasındaki verilere dayalı olarak üç yıl öncesinden öngörmeye yöneliktir. Ayrıca bu çalışmanın özelliği olarak ikinci grup örneklemde 1977 yılındaki finansal başarısızlıklar öngörülme çalışarak, modelin geliştirildiği yıllar ile modelin geçerlilik analizinin yapıldığı yıllar farklılaştırılmıştır. Böylelikle modelin değişik yıllar itibariyle geçerliliği ölçülmüştür.³³

Modellerde kullanılacak değişkenler “finansal esneklik” kavramına dayanılarak seçilmiştir.³⁴ “Finansal esneklik kavramı işletmenin fon akım dengesini, ödeme gücünün bir dayanağı olarak görmekte; fon akımında meydana gelen açıklar, firmanın finansal esneklik kaynaklarına bağlı olarak kapatılabilmektedir.”³⁵ Bu kaynaklar; borçlanma kapasitesi, stok esnekliği, maliyet esnekliği, kar payı esnekliği ve varlıkların elden çıkarılmasıdır.³⁶

Bu çalışmada her 3 model için, işletmenin finansal açıdan durumunu öngörecekle 5 logit fonksiyon geliştirilmiştir. Bu modellerin öngörü başarıları Tablo 3.4’de özetlenmiştir. Ancak yazarlar Logit’in olasılıklı öngörü yaptığını hatırlatarak modellerin sonuçlarını kesin ifadelerle

³³ A.g.e., pp.128-129.

³⁴ A.g.e., p.129.

³⁵ A.g.e.

³⁶ A.g.e.

dönüştürmüşlerdir.³⁷

Tablo 3. 4 : Hing-Lau tarafından geliştirilen 3 modelin öngörü başarıları

| Modeller | Orijinal Örneklem Başarısı % | | | Kontrol Örneklem Başarısı % | | |
|----------|------------------------------|---------------|---------------|-----------------------------|---------------|---------------|
| | Model 1 Yıl 1 | Model 2 Yıl 2 | Model 3 Yıl 3 | Model 1 Yıl 1 | Model 2 Yıl 2 | Model 3 Yıl 3 |
| Durum 0 | 99,4 | 98,9 | 99,1 | 85,4 | 86,5 | 93,7 |
| Durum 1 | 65 | 15 | 10 | 50 | 20 | 10 |
| Durum 2 | 86,7 | 66 | 46,7 | 66,7 | 33,3 | 46,7 |
| Durum 3 | 70 | 40 | 30 | 20 | 10 | 20 |
| Durum 4 | 60 | 100 | 80 | 20 | 20 | 20 |
| Toplam | 96 | 92 | 90 | 80 | 79 | 85 |

Kaynak: HING Amy- LAU Ling, "A Five State Financial Distress Prediction Model", *Journal of Accounting Research*, V:25 N:1 (Spring 1987), p.137.

Modelde işletmelerin sınıflandırılabilmesi için 5 durum olduğunda yanlış sınıflandırma için daha fazla seçenek bulunur; ikili sınıflandırmalarda iki durum arasında hatayı en küçükleyen bir kopuş noktasının seçilmesi söz konusu olurken, bu çalışmada işletmeler için 5 durumun bulunması böyle bir olanağı ortadan kaldırır. Ayrıca modellerin geliştirilmiş olduğu yıllar ile güvenilirlik testinin yapıldığı yıllar farklıdır. Bunların modelin başarısını azaltan faktörler olduğu çalışmanın değerlendirilmesinde dikkate alınması gerekmektedir.³⁸

Nakit akımının, finansal oranlardan oluşturulmuş modellerin öngörü yeteneğine olan katkısının incelendiği bir çalışmada, 290 işletmenin 5 ve 6 yıllık finansal bilgilerinden oluşan bir örneklem kullanılmıştır. Bu örneklemdeki işletmelere ait verilere öncelikle sadece finansal oranları kullanan Logit ve ayırma analizi modelleri, daha sonra

³⁷ A.g.e., p.133.

³⁸ A.g.e. p.136.

ise faaliyetlerden doğan nakit akımı, faaliyetlerden doğan nakit akımı/toplam yükümlülükler, faaliyetlerden doğan nakit akımı / cari yükümlülükler olmak üzere 3 değişken eklenerek, tekrar Logit ve ayırma analizinin kullanıldığı yeni modeller geliştirilmiştir. Çalışmada nakit akışına ilişkin değişkenlerin modellerin öngörme yeteneklerini arttırıcı bir etkileri olmadığı sonucuna varılmıştır.³⁹ Bu çalışmada ayrıca, sadece nakit akımına dayalı verilerin kullanıldığı tek değişkenli bir modeli içeren ön çalışmalarda, nakit akımının finansal oranlara göre finansal başarısızlığı öngörmede yetersiz olduğu belirtilmektedir.⁴⁰

Fon akımının öngörmedeki yeterliliğini inceleyen bir başka çalışmada 33 başarısız 33 başarısız olmayan işletmeye ait bilgilerden oluşan örnekleme, ayırma analizi, Logit ve Probit teknikleriyle modeller geliştirmiş, Logit ile oluşturulan modelin en iyi sonuçları vermesinden dolayı sadece bu modelin sonuçları ele alınmıştır. Fon akımına ilişkin 8 değişkenin kullanıldığı bu Logit modeli ilk yıl için başarısız işletmeleri % 78,79, başarısız olmayan işletmeleri % 87,76 doğru sınıflandırma oranıyla öngörmüştür. Modelin üç yıllık veriler üzerindeki başarısız işletmeleri doğru sınıflandırma oranı % 78,79 ve başarısız olmayanlar için ise % 75,76 dir. 3 yıllık farklı işletmelerin oluşturduğu örnekleme model test edildiğinde, daha düşük (% 70-% 78) başarı elde edilmiştir. Bu çalışmada kar payına ilişkin fon akımlarının, işletmeleri sınıflandırmada önemli olduğuna

³⁹ CASEY Cornelius – BARTCZAK Norman, “ Using Operating Cash Flow Data to Predict Financial Distress: Some Extensions” *Journal of Accounting Research*, V:23 N:1 (Spring 1985), pp.384-401.

⁴⁰ Ayrıca Bkz: CASEY Cornelius – BARTCZAK Norman, “Cash Flow-It’s Not the Bottom Line”, *Harvard Business Review*,(July-August1984), pp.60-68.

dikkat çekilmiştir.⁴¹ Bu araştırmanın devamı niteliğindeki başka bir çalışmada nakit akımına dayalı değişkenler ve finansal oranlar ile, her ikisinin bileşiminin finansal başarısızlığı öngörmedeki başarıları yönünden karşılaştırılmış ve önceki çalışmalardan farklı bir sonuca varılmıştır. Başlangıçta modellerin geliştirilmesinde Probit ve ayırma analizinin ikisinin de kullanılmasına rağmen, sadece Probit analiziyle elde edilen modelin daha iyi sonuçlar üretmesi nedeniyle, değerlendirmeye alınmıştır. Sonuç itibariyle nakit akımına dayalı değişkenler, finansal oranlara göre modelin öngörü başarısını biraz daha arttırmaktadır. Bununla beraber finansal oranların, nakit akımına dayalı değişkenlerle birlikte modelde yer almaları modelin öngörü başarısında herhangi bir gelişmeye neden olmadığı anlaşılmıştır.⁴²

1988 yılında Aziz, Emanuel ve Lawson tarafından yapılan bir araştırma nakit akımının finansal başarısızlığı öngörmede kullanılmasına ilişkin başarılı bir örnektir. Çalışmanın en önemli özelliği daha önceki çalışmalardan farklı bir nakit akımı modeli ve bu modele dayanan verilerin kullanılmış olmasıdır. Bu nakit akımı modelinin farklılığı; yönetimin dikkatini çekmek amaçlı değil, işletmenin pazar değerini nakit akımlarına dayalı olarak tespit etmek amaçlı olmasıdır. Finansal başarısızlığı öngörmede olumlu etkisi olacağı düşünülen nakit akımı modelinin değişken olarak kullanılan ilgili kısımları aşağıda

⁴¹ GENTRY James A.- NEWBOLD Paul-WHITFORD David T., "Classifying Bankrupt Firms with Fund Flow Components", *Journal of Accounting Research*, V:23 N:1 (Spring 1985), pp.146-160.

⁴² GENTRY James A.- NEWBOLD Paul-WHITFORD David T., "Fund Flow Components, Financial Ratios and Bankruptcy", *Journal of Business Finance and Accounting*, C:14 N4 (Winter 1987), pp.595-605.

verilmiştir.⁴³

İşletmenin Nakit akımları=Borçlarla ilgili nakit akımı + Özkaynaklarla ilgili nakit akımı

veya sembolik olarak

$$(k_j+h_j)-(A_j+R_j+Y_j)-H_j-t_j=(F_j-N_j-M_j)+(D_j-B_j)$$

Burada;

(k_j+h_j) = yıl j için müşterilerden yapılan tahsilat k_j ve faaliyetler için kullanılan h_j ,

$(A_j+R_j+Y_j)$ = net sermaye yatırımını yani yenileme yatırımı A_j , büyüme yatırımı R_j , y_j ise elden çıkartılan sabit varlıkları göstermektedir,

H_j = yıl j için likidite değişimi,

t_j = yıl j içinde her türlü vergi ödemeleri,

F_j = yıl j içindeki faiz ödemeleri,

N_j = yıl j içinde artan veya geri ödenen orta ve uzun vadeli krediler,

M_j =artan veya geri ödenen kısa vadeli borçlar,

D_j = işletme hissedarlarına ödenen kar payları,

B_j = Özkaynaklardaki artış veya geri ödemeler.

⁴³ AZİZ Abdül – EMANNUEL Davit C.- LAWSON – Gerald H., “Bankruptcy Prediction – An Investigation at Cash Flow Based Models”, *Journal of Management*, V:25 N:5 (September 1988), pp. 419-437

1971-1982 dönemindeki 49 başarısız ve 49 başarısız olmayan işletmenin incelendiği ve eşlemeli örnekleme tekniğinin kullanıldığı çalışmada işletme büyüklüğü veya endüstri kolu sınıflandırmasına gidilmemiştir. Ayırma analizi ve Logit tekniğiyle finansal başarısızlıktan 1., 2., 3., 4. ve 5. yıllar için modeller geliştirilmiştir.⁴⁴

Değişkenlerin profil incelemesinde başarısız ve başarısız olmayan işletmelere ait değişkenlerin grup ortalamaları arasındaki fark için yapılan testlerde, şu sonuçlar bulunmuştur. Özellikle kj-hj, tj finansal başarısızlıktan 5 yıl öncesinde ve Fj-N-Mj ile Aj+Rj-Yj başarısızlıktan 1 ve 2 yıl öncesinde yüksek düzeyinde anlamlıdır. Ancak Hj başarısızlıktan 5 yıl öncesinde sadece %5 anlamlılık düzeyinde anlamlıdır ve Dj-Bj hiçbir yıl için anlamlı bulunmamıştır.⁴⁵

Değişkenlerle ilk olarak ayırma analizi yapılmıştır. Ancak daha sonra yapılan Logit analizi daha iyi sonuçlar üretmiştir. Her yıl için, Dj-Bj değişkeni dışarıda tutularak bir Logit modeli geliştirilmiş ve modeller % 78,6-% 91,8 arasında doğru sınıflandırma performansı göstermişlerdir. Ayrıca ara sonuç olarak Logit'in ayırma analizine göre daha üstün sonuçlar ürettiği sonucuna da ulaşılmıştır.⁴⁶

Bu çalışmada modelin özellikle 4.ve 5. yıllarda finansal başarısızlığı, finansal başarısız olmayan işletmelere göre daha yüksek doğruluk oranıyla tahmin etmesi, ilgi çekicidir. Çünkü başarısızlığı öngörmedeki hatanın maliyeti, başarısız olmayan işletmeleri öngörmedeki hatanın maliyetinden daha fazladır. Modellerin ulaştıkları doğruluk oranları Tablo 3.5'de

⁴⁴ A.g.e., p.422.

⁴⁵ A.g.e., pp.423-425.

⁴⁶ A.g.e.,pp.427-428.

özetlenmiştir.

Tablo 3. 5 : Aziz, Amanuel ve Lawson tarafından nakit akımı verilerine dayalı Logit tekniğiyle elde edilen sınıflandırma doğruluğu

| | Yıl 1 | | | Yıl 2 | | | Yıl 3 | | | Yıl 4 | | | Yıl 5 | | |
|---|-------|------|-------|-------|------|-------|-------|------|-------|-------|------|-------|-------|------|-------|
| | T | Bsz | B.ol. | T | Bsz | B.ol. | T | Bsz | B.ol. | T | Bsz | B.ol. | T | Bsz | B.ol. |
| 1 | 91,8 | 85,7 | 97,9 | 78,6 | 79,6 | 77,6 | 77,6 | 75,5 | 79,6 | 77,1 | 72,9 | 81,3 | 71,9 | 78,3 | 65,1 |
| 2 | 78,1 | 85,4 | 70,8 | 84,7 | 85,7 | 83,7 | 76,5 | 81,6 | 71,4 | 80,2 | 85,4 | 75 | 76,4 | 82,6 | 69,8 |
| 3 | 82,7 | 85,7 | 79,6 | 79,6 | 81,6 | 77,6 | 78,6 | 79,6 | 77,6 | 79,2 | 81,3 | 77,1 | 75,3 | 80,4 | 69,8 |
| 4 | 84,6 | 89,8 | 79,6 | 76,5 | 75,5 | 77,6 | 74,5 | 73,5 | 75,5 | 80,2 | 81,3 | 79,2 | 75,3 | 78,3 | 72,1 |
| 5 | 73,5 | 81,6 | 65,3 | 73,5 | 83,7 | 62,5 | 75,5 | 81,6 | 69,4 | 77,1 | 81,3 | 72,9 | 80,9 | 84,8 | 76,7 |

T: Toplam Bşl : Başarısız B. ol : Başarısız olmayan

Kaynak: AZIZ Abdül – EMANNUEL Davit C.- LAWSON – Gerald H., “Bankruptcy Prediction – An Investigation at Cash Flow Based Models”, *Journal of Management*, V:25 N:5 (September 1988), p. 430.

Ayrıca bu çalışmayla elde edilen sonuçlarda Gentry, Newbold ve Whitford ‘un çalışmalarından daha yüksek doğruluk oranı gözlemlenirken, Altman’ın Zeta Analizi ile karşılaştırıldığında toplam doğrulukta Altman’ın Zeta Analizi’ne yakın değerler elde edilmiştir. Başarısız işletmeleri doğru sınıflandırma oranı açısından değerlendirildiğinde, Altman’ın Zeta analizi sadece ilk 2 yıl için daha iyi sonular elde etmiş, bu çalışmada kullanılan Logit modeli ise 3-5 yıl öncesi için başarısızlığı daha yüksek doğruluk oranıyla öngörebilmiştir.⁴⁷

Finansal başarısızlığı öngörmeye kullanılan bir başka teknik çoklu regresyon tekniğidir. Çoklu regresyon tekniğini kullanan çalışmalara örnek olarak, başarısız ve başarısız olmayan bankalardan oluşan 30 çift örneklem üzerinde geliştirilmiş bir model içeren çalışma

⁴⁷ A.g.e.,pp.431-435.

incelenmiştir. Ayrıca 9 çiftten oluşan örneklem verilerinde geçerlilik testi için kullanılmıştır. Finansal başarısızlıktan 6 yıl öncesine kadar (finansal başarısızlığın gerçekleştiği yıl hariç) bankalara ait bilgilerden elde edilen 32 finansal oranın kullanıldığı çalışmada, finansal başarısızlıktan önceki 2 yıl için 5 ila 9 değişkenin kullanıldığı regresyon denklemleri elde edilmiştir. Finansal başarısızlıktan 1 yıl öncesi için % 83, iki yıl öncesi içinde % 78 doğrulukla sınıflandırma yapılmıştır.⁴⁸

3.1.1.2.4. Piyasa Verilerinin Değişken Olarak Kullanıldığı Modeller

Sermaye piyasası verilerinin işletmelerin finansal başarısızlığını öngörmeye kullanılmasına ilişkin model önerisi içeren bir çalışma, aynı zamanda finansal başarısızlığa yönelik işletmelerin risk düzeyinde ve hisse senedi fiyatında meydana gelebilecek değişiklikleri de incelemesi bakımından oldukça önemlidir. Örneklem olarak 45 başarısız işletme ile 65 başarısız olmayan işletmenin incelendiği çalışmada, örnekleme giren işletmelerin bilgileri 1970-1978 dönemine aittir. Çalışma kabaca üç bölüm halinde tasarlanmıştır. İlk bölümde, başarısız işletmeler ile başarısız olmayan işletmelerin risk açısından gösterdikleri değişkenlik karşılaştırılmış ve bu işletmeler arasında risk açısından önemli fark olduğu tespit edilmiştir. Bu değişikliklerin işletme finansal başarısızlığı yaşamadan 4 yıl öncesinde gözükmeye başladığı da gözlemlenmiştir. İkinci bölümde ise finansal başarısızlık eğilimine giren işletmeler ile bu eğilimi taşımayan işletmelerin getirilerindeki değişim incelenmektedir. Finansal başarısızlığı belli bir süreç içinde yaşayan işletmelerde, pazar getirisi, işletme

⁴⁸ MEYER Paul A. – PIFER Howar W., “Prediction of Bank Failures”, *The Journal of Finance*, C:25 N:7 (September 1970), pp.853-858.

finansal başarısızlığa tam anlamıyla düşmeden önce ve sonra eşit olacağı, çünkü pazarın finansal başarısızlığı önceden sezinleyerek hisse senedi fiyatında gerekli düzeltmeyi önceden yapacağı hipotezi test edilmektedir. Nitekim örnekleme yer alan işletmelere ait hisse senetlerinin 4 yıllık dönemde haftalık ortalama getirisi finansal başarısızlığa yaklaştıkça negatif olmaktadır. Ancak finansal başarısızlıktan 7 hafta önce yaşanan keskin düşüşün, yatırımcıların başarısızlığın gerçekleşmesini bu kadar erken beklemediklerini göstermektedir. Üçüncü bölüm olarak da, hisse senedinin getirisinin üçer aylık gösterdiği değişkenliğe bağlı olarak öncelikle incelenen işletme için finansal başarısızlık olasılığı belirlenir ve daha sonra aynı dönem için aynı endüstrideki diğer işletmeler için belirlenen finansal başarısızlık olasılığıyla karşılaştırılır.⁴⁹

3.1.1.2.5. Finansal Raporların Hazırlanma Süresini Değişken Olarak Kullanan Modeller

Finansal başarısızlığı ortaya çıkaran olayların gerçekleşme zamanı ile finansal raporlama zamanlaması arasındaki ilişkiye ilk dikkat çeken, Ohlson'un yapmış olduğu çalışmadır.⁵⁰ Finansal raporlama zamanının işletmelerin finansal başarısızlıklarına işaret edebileceği önyargısı, finansal raporların hazırlanma sürelerini veri olarak alan araştırmaların tasarlanmasına neden olmuştur. Yazında bu noktayı ele alan çalışmaların da az olmadığı görülmüştür.

⁴⁹ AHARONY Joseph- JONES Charles P.- SWARY Itzhak, "An Analysis of Risk and Return Characteristics of Corporate Bankruptcy Using Capital Market Data", *The Journal of Finance*, V:XXXV N:4 (September 1980), pp.1001-1016.

⁵⁰ OHLSON, A.g.e.

Finansal başarısızlık ile finansal raporlama zamanlaması arasındaki ilişkiye kesitsel bir bakış yapıldığında; finansal başarısızlığa uğrayan işletmelerin, finansal raporları yılın bitiminden sonra en az 4 ay geciktirerek, finansal başarısızlıkla ilgili olayın ortaya çıkmasından sonra finansal raporları açıkladıkları anlaşılmaktadır. Buna gerekçe olarak işletme yöneticilerinin, finansal tablolarındaki bilgilerin öğrenilmesi sonucu ilgililerin ortaya koyacağı sert tepkiden kaçınmak, olabileceği varsayılmaktadır.⁵¹

Whittred ve Zimmer tarafından yapılan bir çalışmada işletmelerin finansal tablolarının hazırlanması, bağımsız denetimden geçme ve yayımlanma sürelerinin işletmelerin finansal başarısızlıklarını öngörmeye kullanılıp kullanılmayacağını araştırılmıştır. Bu amaçla 37 çift işletmenin 5 yıllık verileri üzerinde yapılan çalışmada, finansal yıl sonunda i) denetlenmemiş finansal tabloların Sydney Sermaye Piyasasının (SSP) eline geçiş tarihi, ii) bağımsız denetçinin görüşüne ait raporu imzaladığı tarih ve iii) yayınlanan finansal tablonun SSP'nin eline geçiş tarihi arasındaki süreler veri olarak kullanılmıştır. Doğrusal ayırma analiziyle sadece finansal tabloların hazırlanma sürecini veri olarak kullanan, sadece finansal oranları veri olarak kullanan ve finansal tabloların hazırlanmasına ilişkin sürelerle birlikte finansal oranları da veri olarak kullanan üç model geliştirilmiştir. En yüksek öngörü doğruluğu finansal oranları veri olarak alan model sağlamıştır.⁵²

Bu çalışmadan farklı sayılabilecek sonuçlara varan Keasey ve Watson, finansal oranların başarısızlığı öngörmedeki üstünlüklerini kabul etmekle birlikte, bu durumun

⁵¹ LAWRENCE Edward C., "Reporting Delays dor Failed Firms" *Journal of Accounting Research*, V:21 N:2 (Autumn 1983), pp.606-609.

⁵² WHITTRED Gred- ZIMMER Ian, "Timeliness of Financial Reporting and Financial Distress", *The Accounting Review*, V:LIX N:2 (April 1984), pp.287-295.

sadece büyük, muhasebe sistemi gelişkin ve finansal raporlamasını zamanında yapan işletmeler için geçerli olabileceğini belirtmişlerdir. Küçük işletmelerde, işletmeyle ilgili tarafların işletme üzerindeki baskısının az olmasından dolayı, muhasebe raporlarının zamanında elde edilemediği veya çok geç elde edildiği gerçeğine dayanarak, finansal raporlama zamanlamasını veri alan bir öngörü modelinin daha iyi sonuçlar vereceğini savunmaktadırlar. Nitekim geliştirilen dört modelden finansal raporlarını gerekli yerlere hiç göndermeyen işletmeleri başarısız, finansal raporlarını zamanında gönderenleri başarısız olmayan işletme olarak kabul eden basit ilk modelin toplam doğru sınıflandırma oranı %58,9 olmuştur. Model daha da geliştirilerek, küçük işletmelerin finansal raporlarını ilgili birime ortalama olarak 11,3 ay geç hazırladıkları için 12 ay ve sonrasında finansal tablolarını hazırlayan işletmeler başarısız kabul edildiği, geri kalanların ise iki finansal oran kullanan ayırma analizine tabi tutulduğu Model 2 başarısız işletmeleri % 65,8 ve başarısız olmayan işletmeleri % 69,9 ortalama olarak da % 67,8 doğrulukla öngörmüştür. Finansal raporlarını 12 ay geciktiren işletmeler için Bayesian olasılık kuralını uygulayarak öngöründe bulunan model ortalama %63,7; finansal raporlarını 12 ay geciktiren işletmeler için ayırma analizini uygulayan model %67,8 doğru sınıflandırma oranı yakalamıştır. Yazarlar finansal raporlama davranışları farklı olan küçük işletmeler için, finansal raporların zamanlamasına dayalı bir modelin, özellikle finansal raporlamanın geciktiği veya hiç finansal raporların bulunmadığı durumlarda daha başarılı olacağı sonucuna varmışlardır.⁵³

⁵³ KASEY Kevin – WATSON Robert, “The Non-submission of Accounts and Small Company Financial Failure Prediction”, *Accounting and Business Research*, V:19 N:73 (Winter 1988), pp.47-54.

Aynı yazarlar tarafından yapılan başka bir araştırmada küçük işletmelerde finansal oranların kullanımıyla ilgili sorunlara dikkat çekilerek, finansal başarısızlıkta finansal oranlardan oluşan değişkenler ile finansal olmayan değişkenlerin öngörü gücü karşılaştırılmıştır. Logit tekniğinin kullanıldığı çalışmada 73'ü başarısız 73'ü başarılı olmayan 146 işletme kullanılmıştır. Bunlardan 20 çifti ise geçerlilik testi için ayrılmıştır. Değişken olarak sadece finansal oranların yer aldığı Model 1, sadece finansal olmayan değişkenlerin yer aldığı Model 2 ve finansal oranların ve finansal olmayan değişkenlerin birlikte yer aldıkları Model 3 adlı üç modelin karşılaştırılmasında; sadece finansal oranların kullanıldığı Model 1 %76,7, sadece finansal olmayan değişkenlerin kullanıldığı Model 2 %75,3 ve her iki değişken türünün kullanımıyla % 82,2 öngörü başarısı elde edilmiştir. Genel olarak doğru sınıflandırma yüzdeleri düşmüş ve finansal değişkenler ile finansal olmayan değişkenlerin doğru sınıflandırma başarıları farklılaşmışsa da, geçerlilik testi sonuçları finansal olmayan değişkenlerin küçük işletmelerde yapılacak finansal başarısızlık öngörülerinde önemli olduğunu işaret etmektedir.⁵⁴

3.1.1.3.Felaket Teorisine Dayanan Modeller

Finansal başarısızlık konusunda teorik bir yapı oluşturmak amacıyla “felaket teorisi” (catastrophe theory) yaklaşımını kullanan çalışmalar bulunmaktadır.⁵⁵ Felaket teorisi bir sistemde istikrarı sağlayan değişkenlerdeki küçük bir değişikliğin sistemde neden olduğu ani

⁵⁴ KEASEY K.[Kevin]-WATSON R.[Robert], “Non-financial Symptoms and The Prediction of Small Company Failure: A Test of Argenti’s Hypotheses” ,*Journal of Business Finance & Accounting*, V:14 N:3 (Autumn 1987), pp.335-354.

⁵⁵ HO Thomas – SAUNDERS Anthony, “ A Catastrophe Model of Bank Failure”, *The Journal of Finance*, V:XXXV, N:5, (December 1980), pp.1189-1207.;SCAPENS Robert W. – RYAN Robert J. – FLETCHER Leslie, “Explaining Corporate Failure : A Catastrophe Theory Approach”, *Journal of Business Finance & Accounting*, V: 8, N:1, (1981), pp.1-26.

değişimi açıklamaya çalışan teorik bir yaklaşımdır.⁵⁶

Sistemin alabileceği en büyük ve en küçük değerler, bir sistemin kritik noktalarını oluşturur ve o sistemde oluşabilecek değişik denge noktalarını gösterir. Felaket teorisi de bu denge noktalarıyla ilgilenmekte olup; özellikle $f(x) = X^2$ gibi fonksiyonlarla tanımlanabilen sistemlerin değişkenlerinde meydana gelen değişiklikler, sistemin kritik noktalarında önemli değişiklikler oluşturmazken; $f(X) = X^4$ fonksiyonu gibi fonksiyona sahip parabolik sistemlerde değişkenler birden fazla minimum ve maksimumla çok sayıda kritik nokta oluşturabilirler.⁵⁷

Bu dalgalanmalar sistemde istikrar bozulmaları olarak değerlendirilmektedir.

Teori üç ana temel üzerine dayanmaktadır.⁵⁸

- i. Başlangıç noktalarındaki küçük bir değişiklik, sistemde önemli kesintilere neden olabilmektedir.
- ii. Sistemin davranışı bazı parametrelerin değişimine karşı, daha önceki davranışının tam tersi (asimetrik) tepki gösterebilmektedir.
- iii. Felaket durumu sistemin yapısal ilişkilerindeki marjinal değişmelere karşı güçlüdür.

Bu dalgalanmalara, yani sistemin asimetrik davranışına neden olan değişken "ayrıcı " (splitting) değişken olarak adlandırılmaktadır.⁵⁹

⁵⁶ SCAPENS- RYAN- FLETCHER, A.g.e.

⁵⁷ A.g.e.

⁵⁸ HO-SAUNDERS, A.g.e., p.1190

⁵⁹ SCAPENS- RYAN- FLETCHER, A.g.e., p.2.

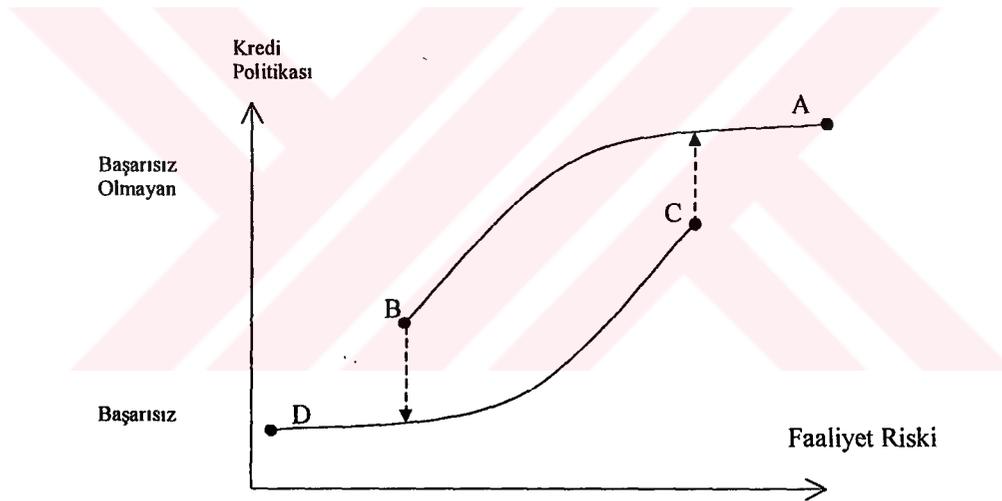
Felaket teorisi, finansal başarısızlık alanına uygulandığında, muhasebe verilerindeki değişmelere karşı işletmenin varlığını sürdürmede hayati rol oynayan kredi verenler ve yatırımcıların gösterdikleri tepkileri açıklamaya çalışmaktadır.

Özellikle zor durumda bulunan işletmelerin başarısızlığa düşmelerinin altında yatan bir neden olarak, kredi verenlerin aniden kredileri kesmesi bulunmaktadır. Bu ani değişimin niçin gerçekleştiğinin anlaşılmasında ise söz konusu felaket teorisinden yararlanılmaktadır.⁶⁰ Kredi verenler kredi politikalarını belirlerken kredilerini başarılı işletmelere genişletmek, bununla beraber başarısız işletmelerden çekmek isterler. Kredi verenler başarılı-başarısız ayrımında işletmenin getirisini dikkate almaktadırlar. Bu getiri kar, nakit veya fon akışı olarak değerlendirilebilir. İşletmenin getirisi arttıkça kredibilitesi yükselirken, getirisi düştükçe kredibilitesi de düşer. Ancak, kredi verenler işletmenin getiri düzeyindeki değişkenliği ifade eden faaliyet riskini değerlendirirken, başarısız olmayan ve başarısız işletmeler arasında farklılık gözetirler(Şekil 3.2). Kredi verenler, getirisi A ve B gibi belirli bir aralıktaki işletmeleri başarısız olmayan işletme sınıfına dahil ederken, getirisi B noktasından daha düşük gerçekleşen işletmeler başarısız sınıfına dahil ederler. Aynı şekilde getirisi C ve D aralığında olan işletmeler başarısız, C noktasından daha fazla getirisi olan işletmeler ise, başarısız olmayan işletme sınıfına dahil edilirler. İşletmeye, girdiği başarısız ve başarısız olmayan sınıflardan birine uygun olarak da, değişik kredi politikaları uygulanacaktır. B-C aralığında getirisi olan bir işletmenin ise hangi kredi politikasına tabi olacağı daha önceki getirisine ve daha önce ait olduğu gruba bağlı kalacaktır. Aynı getiri düzeyinde olmasına rağmen, önceki getiri düzeyinden dolayı iki işletme farklı kredi politikalarına tabi olabilir. Ancak B-C

⁶⁰ A.g.e., pp.6-7.

noktalarının ötesine geçildiğinde, kredi verenler işletmenin getirisindeki en küçük bir değişikliğe karşı büyük bir tepki göstererek, işletmeyi iki gruptan birine “sıçrama yaparak” yeniden sınıflandıracaktır. Bu noktalarda kredi verenlerin tepkileri ani ve daha önceki davranışlarıyla ters yönlü olmaktadır. Özellikle daha önce başarısız olmayan sınıfına ait bir işletmenin, aniden başarısız olarak yeniden sınıflandırılması, zor durumda olan bu işletme açısından, potansiyel bir başarısızlık durumunu gündeme getirecektir.⁶¹

Şekil 3. 2: İşletmelerin değişik kredi politikalarına geçişi



Kaynak : SCAPENS Robert W. – RYAN Robert J. – FLETCHER Leslie, “Explaining Corporate Failure : A Catastrophe Theory Approach”, *Journal of Business Finance & Accounting*, V: 8, N:1, (1981), p.9’den değiştirilerek alınmıştır.

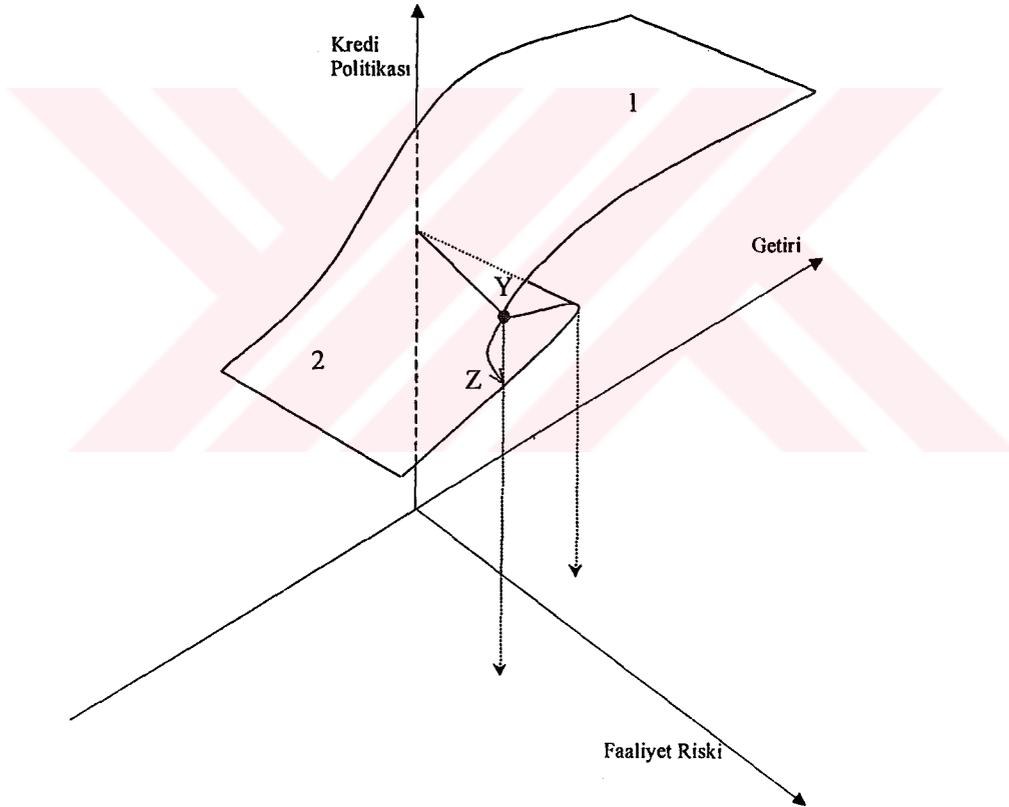
⁶¹ A.g.e., pp.6-11.

İşletmenin getirisi ve faaliyet riski arasındaki ilişki ile kredi politikasının oluşturduğu üç boyutlu ilişki (Şekil 3.3) aşağıdaki gibi bir formülle tanımlanabilir.⁶²

$$F_{ab}(x) = x^4 + 2ax^2 + 4bx$$

Burada: x= kredi politikası, a= ölçülebilir getiri, b= faaliyet riskidir.

Şekil 3.3 : Kredi politikasında felaket modeli



Kaynak : SCAPENS Robert W. – RYAN Robert J. – FLETCHER Leslie, "Explaining Corporate Failure : A Catastrophe Theory Approach", *Journal of Business Finance & Accounting*, V: 8, N:1, (1981), p.11'den değiştirilerek alınmıştır.

⁶² SCAPENS- RYAN- FLETCHER, A.g.e., p.2.

Şekil 3.3'de işletmenin Y noktasından Z noktasına geçişi, işletmeye kredi verenlerin işletmenin getirisinde ve faaliyet riskinde meydana gelen değişikliğe karşı gösterdikleri tepki ve işletmenin yeni kredi sınıflandırmasına geçişini ifade etmektedir. İşletmenin 1. yüzeyden 2. yüzeye sıçramalı ani düşüşü bir felaket olarak nitelendirilebilir ve işletme eğer zor durumda ise potansiyel bir başarısızlık söz konusu olabilecektir.

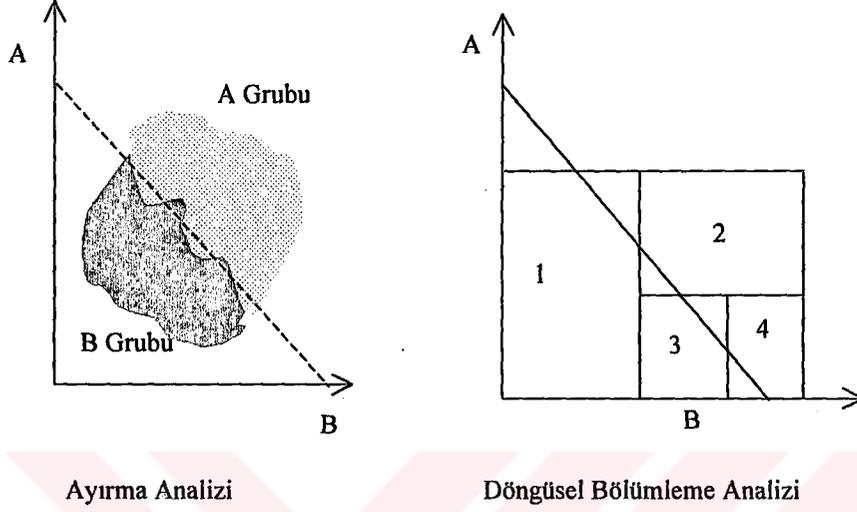
Felaket teorisi, işletmelerin finansal başarısızlığı açısından iyi bir teorik yapı sunmasına rağmen, yapılan çalışmalarda herhangi bir uygulamalı sonuç elde edilmemiş olunmasından dolayı teorik bir önerme olmaktan öte geçemediği söylenebilir.

3.1.1.4. Parametrik Olmayan Modeller

Çalışmanın bundan önceki bölümlerinde ele alınan parametrik nitelikteki teknikleri kullanan modellerde, çalışmanın ileriki bölümlerinde ayrıntılı olarak incelenecek olan çok sayıda sorun bulunmaktadır. Bu sorunlar genel olarak tekniklerin varsayımlarından ve uygulama güçlüklerinden kaynaklanmaktadır. Bu sorunlara sahip olmayan Döngüsel Bölümleme Analizi ayırma analizi gibi beklenen hatalı sınıflandırma maliyetinin minimize eden Bayesian süreçleri kullanır. Aralarındaki farklılık değişken uzayını bölümlendirmede kullandıkları sınıflandırma bölgeleridir. Ayırma analizi değişken uzayını sadece iki düzleme ayırırken döngüsel bölümleme analizi değişken uzayını değişik sayıda dörtgenlere ayırmaktadır(Şekil 3.4).⁶³

⁶³ ALTMAN Edward I., Corporate..., pp.237-238.

Şekil 3. 4 : Çok değişkenli ayırma analizi ve döngüsel bölümlleme analizi arasındaki farklılık



Kaynak : ALTMAN Edward I., *Corporate Financial Distress and Bankruptcy: A Complete Guide to Predicting and Avoiding Distress and Profiting from Bankruptcy*, Second Ed., John Wiley and Sons, Inc., New York, 1993, p. 183 ve p. 239'dan değiştirilerek alınmıştır

Şekil 3.4 'de döngüsel bölümlleme analizine ait grafikte görülen gri alan ayırma analizi ve döngüsel bölümlleme analizi arasında değişkenleri sınıflandırmadaki farklılığı göstermektedir.

Ayırma analiziyle arasındaki bir diğer farklılık ise önsel olasılıklar ve yanlış sınıflandırma maliyetinin modelin sonuçları üzerindeki etkidir. Döngüsel bölümlleme analizinin önsel olasılıklar ve yanlış sınıflandırma maliyetindeki değişikliklere karşı özellikle değişkenin seçiminde daha duyarlı sonuçlar üretir.⁶⁴

⁶⁴ A.g.e., pp.239-240.

Döngüsel bölümlleme analizi kullanılarak yapılan bir çalışmada 1971-1981 döneminde başarısızlığa uğramış 58 ve başarısız olmayan 142 üretici ve ticari işletmeyle çok sayıda döngüsel bölümlleme analizi modeli geliştirilmiştir. 20 finansal oranın kullanılmış fakat araştırmada kullanılan veriler değişik yıllardaki finansal raporlardan elde edilmiş, başarısız ve başarısız olmayan işletmelerin finansal yıllar itibariyle herhangi bir eşlemeye tabi tutulmamıştır. Ayrıca Altman'nın diğer çalışmalarında da olduğu gibi finansal veriler üzerinde finansal kiralama (leasing) ilgili düzeltmeler yapılmıştır. Çalışmada değişik önsel olasılıklar ve yanlış sınıflandırma maliyetiyle çok sayıda model oluşturulmuştur. Sonuçta 7 değişkenin tek boyutlu serisi elde edilmiştir. Aynı zamanda en az 4 en çok 10 değişkenin kullanıldığı ayırma analizine tekniğiyle de modeller geliştirilmiştir. Sonuçta döngüsel bölümlleme analiziyle kurulan modellerin çoğu ayırma analizinin kullanıldığı modellerden daha yüksek doğru sınıflandırma oranını, daha az değişkenle elde etmiştir.⁶⁵

3.1.2. İnsan Yargısına Dayalı Modeller

Finansal başarısızlığın insan yargısına bağlı olarak öngörülmesiyle ilgili olarak önemli katkı sağlayan Libby'in çalışması, oranların, analistlerin finansal başarısızlığı öngörmelerinde yararlı olup olmadığını incelemiştir. Deakin'in kullandığı veri setinden rastgele seçilmiş 60 işletmeye ait veriler kullanılmış ve 43 ticari kredi analistine işletmelerin gelecekte başarısız ve başarısız olmayan sınıflarından hangisine gireceğinin öngörülmesi istenmiştir. Analistlere önsel olasılıkları belirtmek amacıyla, örnekleme finansal tabloları bulunan işletmelerden yarısının üç yıl içinde başarısız duruma düştükleri belirtilmiştir.

⁶⁵ A.g.e., pp.241-242.

Analistlerin tek başlarına bir haftalık zaman içinde analizleri bitirmeleri istenmiştir. Daha sonrasında ise kendilerine her doğru öngörü için bir puan verileceği, her yanlış öngörü için ise bir puan geri alınacağı vurgulanmıştır.⁶⁶

Libby analistlerin öngörü sonuçları üzerinde üç hipotez test etmiştir. Bunlar:⁶⁷

H₁: Analistlerin öngörülleri, örneklemdaki işletmeleri rastgele başarısız ve başarısız olmayan şeklinde sınıflandırmanın doğruluk oranından fark yoktur.

H₂:Analistler içinde büyük ve küçük banka çalışanları arasında öngörü doğruluğu açısından fark bulunmamaktadır.

H₃: Analistlerin 1 hafta arayla yaptıkları analizleri tekrar etmeleri sonucunda güvenilirlikleri eşit olacaktır.

Hipotezlerin test edilmesi sonucunda çalışmada varılan sonuçlar şu şekilde genelleştirilebilir:⁶⁸

- i. Analistlerin öngörü başarıları rastgele seçim sonucu oluşan doğruluk oranından fazladır.
- ii. Büyük ve küçük banka analistleri arasında öngörü başarısı açısından önemli farklılık bulunmamaktadır.

⁶⁶ LIBBY Robert, "Accounting Ratios and the Prediction of Failure: Some Behavioral Evidence", *Journal of Accounting Research*, (Spring 1975), pp.150-161.

⁶⁷ A.g.e.

⁶⁸ A.g.e.

- iii. Analistlerin yaş ve deneyimleri ile öngörü başarıları arasından herhangi bir ilişki bulunamamıştır.
- iv. Analistler kısa süreli olarak analizleri tekrarladıklarında bir farklılık oluşmamıştır.
- v. Analistlerin yorumları arasında bir birlik bulunmuştur.

Libby 'nin araştırmasında yer alan analistler ortalama olarak % 74,4 oranında doğru öngörü yaparken, en iyi öngörü % 81,7 olmuştur.⁶⁹

Bu çalışmanın bazı küçük farklılıklarla tekrarı niteliğinde olan bir başka çalışma ise 46 analist ile 30 işletmenin üç yıllık verilerinden oluşan örneklem kullanılarak yapılmıştır. Çalışmanın sonunda ulaşılan sonuçlar Libby'nin vardığı sonuçlarla karşılaştırılmış ve aşağıdaki konularda tutarsızlıklar saptanmıştır:⁷⁰

- i. Analistlerin öngörü doğruluğu, başarısız işletmeleri öngörmeye daha düşük olmuştur.
- ii. Öngörü başarısındaki istatistiksel olarak önemli büyüklükteki değişiklik, bilgi analizinde bireysel farklılıklarla açıklanabilir.

⁶⁹ A.g.e., p.158.

⁷⁰ CASEY J. Cornelius, "The Usefulness of Accounting Ratios for Subjects' Predictions of Corporate Failure: Replication and Extensions" ,*Journal of Accounting Research*, V:18 N:2,(Autumn 1980), pp.603-613.

- iii. Bileşik yargının öngörü doğruluğu, bireylerin ortalama öngörü doğruluğunu geçememiştir (bileşik yargı her analistden işletme için alınan oyunun, oy çokluğu esas alınarak işletmelerin değerlendirilmesiyle oluşturulmuştur).

Bu tutarsızlıklar iki araştırmanın tasarımındaki farklılıklarla açıklanmakta fakat önsel olasılıkların açıklanmamasının söz konusu tutarsızlığa neden olamayacağı üzerinde durularak belirtilmektedir. Çalışmada yer alan analistlerin ortalama doğruluk oranı % 56,7 (17/30) olurken, başarısız işletmeleri % 26,7 (4/15), başarısız olmayan işletmeler ise % 86,7 (13/15) doğrulukla öngörmüşlerdir. 46 analistin 41'i başarısız olmayan işletmeleri %50'nin üzerinde bir doğruluk oranıyla öngörebilmişlerdir.⁷¹

Finansal başarısızlıkla ilgili olarak, insan yargısının yerini ve işlevini araştıran önemli bir çalışmada, başarısızlığı öngörmeye kullanılan bilgilerin seçiminin ve kullanımının öngörünün başarısını belirleyen önemli bir etken olup olmadığı araştırılmıştır. Yazarlar, daha önce yapılmış olan diğer araştırmalarda yer alan matematiksel ve insan yargısına dayanan modellerde hangi verilerin kullanılacağına araştırmacılar tarafından seçilmesini eleştirerek, gerçek hayatta analistlerin kullanacakları verileri de kendilerinin seçtiklerini, bu nedenle araştırmacı tarafından belirlenen veri grubunun kullanılmasının gerçek hayatla bağdaşmayacağını belirtmişlerdir. Ayrıca, aynı gerekçeyle finansal başarısızlık kavramı olarak, borçların ödenmemesi durumunu kabul edilmiştir. Buna göre gerçek hayatta bilgi kullanıcıları iflas durumuyla değil, işletmenin borçlarını ödeme yeteneğiyle ilgilenmektedir.

⁷¹ A.g.e., p.609.

İflas borçlarını ödeyemeyen bir işletmenin ulaştığı son nokta olmaktadır.⁷²

Araştırmada veri olarak kullanılacak oranların, insan ve matematiksel modeller tarafından seçildiği iki veri kaynağı tespit edilmiştir. Ayrıca matematiksel modelin, insan karar vericinin ve insan modelinin (bu model insan tepkilerini yansıtan bir doğrusal modeldir) kullanıldığı üç farklı bilgi işlem sürecinin oluşturulduğu çalışmada, bu üç farklı bilgi işlem sürecinde yukarıda sözü edilen iki farklı veri kaynağı kullanılarak bir kombinasyon elde edilmiştir.

Bu kombinasyonlar içinde %90,6 öngörü doğrulukla kullanılacak oranların matematiksel olarak seçildiği ve öngörünün yapılmasında matematiksel modellerin kullanıldığı ikili kombinasyon en yüksek başarıyı göstermiştir. İnsanlar tarafından seçilen verilerin kullanıldığı matematiksel modeller %67,5 doğruluk oranını yakalarken, diğer kombinasyonlar sadece %62,5 ortalama doğruluk oranına erişebilmişlerdir.⁷³

Bu çalışmada varılan sonuçlar kendisinden sonra bir çok çalışmaya alt yapı oluşturması ve çok sayıda atıf almasından dolayı önemlidir. Varılan sonuçlar şöyle özetlenebilir:⁷⁴

- i. Kullanılan matematiksel modeller, insan yargılarından daha iyi sonuçlar üretmiştir.
- ii. İnsan yargısının düşük performans göstermesinde, kullanılacak verilerin seçimi

⁷² ABDEL-KHALIK A. Rashad – EL-SHESHAI Kamal M., “ Information Choice and Utilization in an Experiment on Default Prediction”, *Journal of Accounting Research*, V:18 N:2, (Autumn 1980), pp. 325-342.

⁷³ A.g.e., p. 336.

⁷⁴ A.g.e., p.340.

önemli etkiye sahiptir.

- iii. Seçilen bilgilerin kullanılmasında insan yargısı ile matematiksel modeller arasında önemli bir fark bulunmamaktadır.
- iv. Örneklem içindeki önsel olasılıklar yargıların doğruluğuna herhangi bir etki yapmamıştır (yazarlar bu sonucu beklemediklerini belirtmektedirler).
- v. Makul bir doğruluk oranında yargıya varmak, ancak az sayıda veri unsuruna dayanmalıdır.

Kanada bankalarının kredi değerlemesine ilişkin olarak bankerlerin yaptığı öngörü performansı ile ayırma analizi ve özellikle Altman'ın Z katsayısının öngörü performansını karşılaştıran başka bir araştırmada; bankerlere karşı ayırma analizinin krediyi geri ödemede yetersiz olan işletmeleri daha kötü sonuçlar ortaya koyarak sınıflandırdığı tespit edilmiştir (başarısızlıktan 2 yıl öncesi %50, 3 yıl öncesi %29 doğrulukla öngörülmüştür).⁷⁵ Bu çalışma her ne kadar bankerlerin öngörülerinin matematiksel modellere karşı daha güvenilir bulmaktaysa da, büyük ölçüde Kanada işletmeleri ve Kanadalı bankerler baz alınarak tasarlandığı için çalışmanın sonuçlarının Kanada dışı için genelleştirmek güç gözükmektedir.

3.1.3. Yapay Zeka Teknolojisine Dayalı Modeller

Son yıllarda bilgiişlem teknolojisindeki gelişmeler, insan zekasının özelliklerini taklit etmeye yönelik bilgiişlem teknolojilerinin ortaya çıkmasına yardımcı olmuştur. Bu

⁷⁵ DOUKAS John, "Bankers Versus Bankruptcy Prediction Models: An Empirical Investigation, 1979-82", *Applied Economics*, V:18 (1986), pp.479-493.

teknolojiler her ne kadar insanın yerini almayı hedefleseler de, henüz bu yeterlilikte bir teknoloji bulunmamaktadır. Ancak belli özellikleri itibariyle insan zekasının ve düşünme gücünün özelliklerini kısmen yerine getirebilecek teknolojiler bulunmaktadır. Bunların arasında uzman sistemler, yapay sinir ağı teknolojileri, bulanık mantık, genetik algoritmaları sayılabilir. Bu teknolojiler üzerindeki çalışmalar hızla sürmektedir.

Bu teknolojilerden uzman sistemler ve yapay sinir ağlarının finansal başarısızlığın öngörülmesi alanında kullanıldığı görülmektedir.

3.1.3.1.Uzman Sistem Kullanan Çalışmalar

Uzman sistemler en eski yapay us teknolojilerinden biridir. İnsan uzman gerektiren problemlerin çözümünde kullanılan bir bilgisayar teknolojisidir. Sezgisel (heuristic) yöntemlere dayanan uzman sistemler, insan yeteneklerini taklit etmeye çalışırlar ve belli bir alanda sonuç çıkarma yetenekleri vardır. İlk örneklerinin 1960'larda görüldüğü uzman sistemler, sonuç çıkarma yetenekleri insan uzmanlardan aldıkları bilgi birikimine dayandığı için bilgi tabanlı sistemler olarak da anılırlar.⁷⁶

Uzman sistemlerin bu çalışmada kullanılan yapay sinir ağı teknolojisi gibi bir yapay zeka teknolojisi olması açısından, uzman sistemler kullanılarak yapılan finansal başarısızlığı öngörme çalışmaları, yapay zeka teknolojilerine dayalı ilk model denemeleri özelliğini taşımaktadır. Diğer yapay us teknolojilerinde olduğu gibi uzman sistemler ile yapay sinir ağı teknolojilerinin kesiştikleri birçok nokta ve bu teknolojilerin bütünleşik kullanımları olmasına

⁷⁶ TURBAN Efraim, *Decision Support and Expert Systems; Management Support Systems*, Macmillan Publishing Comp., New York, 1993, pp.16;466-472. Ayrıca Bkz: ZAHEDI Fatma, *Intelligent Systems for Business: Expert Systems with Neural Networks*, Waisworth Publishing Comp., California, 1993.

rağmen, konumuzun kapsamını gereğinden fazla genişletmek endişesiyle uzman sistemler konusuna daha fazla yer verilmemiş sadece daha önce matematik- istatistik modellerde olduğu gibi finansal başarısızlığı öngörmeye uygulanış ve sonuçları açısından incelenmiştir.

Uzman sistemin kullanıldığı bir çalışmada, uzman sistemin işletmelerin finansal başarısızlığını öngörmedeki performansı, bireysel yargılar, grup yargıları ve ayırma fonksiyonunun performansı ile karşılaştırılmıştır. Bu karşılaştırmalar için finansal başarısızlığı öngörmeye bireysel insan yargısının, grup yargısının ve ayırma analizinin performanslarını karşılaştırmada kullanılan iki çalışmanın⁷⁷ veri ve sonuçları kullanılmıştır.⁷⁸

EXPERT-EASE adlı uzman sistem yazılımı kullanılarak kurallar ve karar ağaçları oluşturulmuştur. Sonuçlar önce Abdel-Khalik – El-Sheshai'nin çalışmalarıyla karşılaştırılmıştır (Tablo 3.6).

⁷⁷ ABDEL-KHALIK – EL-SHESHAI, A.g.e.; Ayrıca Bkz : LIBBY R.- TROTMAN K.T. – ZIMMER I., Member Variation, Recognition of Expertise and Grup Performance”, *Journal of Applied Psychology*, (1987), pp.81-87.

⁷⁸ MESSIER William F. – HANSEN James V., “Inducing Rules For Expert System Development : An Example Using Default and Bankruptcy Data”, *Management Science*, V:34 N:12 (December, 1988) , pp. 1403-1415.

Tablo 3. 6 : Uzman sistem ile ayırma analiz-insan yargısı ve grup yargısının performans karşılaştırması

| | Öngörü Başarısı | |
|--|------------------------|--------------------------|
| | Deney Grubundaki Sonuç | Kontrol Grubundaki Sonuç |
| Ayrırma Analizi | | |
| <i>Deneysel Çalışmada Geliştirilen Ayrırma Analizi Modeli</i> | % 90,6 | Belirtilmemiş |
| <i>Geçerlilik Testinde Geliştirilen Ayrırma Analizi Modeli</i> | %100 | % 57 |
| Uzman Sistem Tarafından Geliştirilen Kurallar | | |
| <i>Deneysel/Kontrol Grubundan Geliştirilen</i> | % 100 | % 87,5 |
| <i>Geçerlilik/Kontrol Grubundan Geliştirilen</i> | % 100 | % 87,5 |

Kaynak : MESSIER William F. – HANSEN James V., "Inducing Rules For Expert System Development : An Example Using Default and Bankruptcy Data", *Management Science*, V:34 N:12 (December, 1988) , pp. 1403-1415.

Tablonun yorumlanmasında, uzman sistemin deneysel ve geçerlilik çalışmalarında örneklem grubu üzerinde % 100 başarılı sınıflandırma yapıncaya kadar kurallar geliştirmeye devam ettiği ve bu nedenle uzman sistem tarafından geliştirilen kuralların örnekleme %100 oranında doğrulukla sınıflandırmasının beklenen bir durum olduğu dikkate alınmalıdır. Ancak Tablo 3.6' da görüldüğü üzere uzman sistem deneysel ve geçerlilik çalışmalarının kontrol gruplarının her ikisinde de % 87,5 başarıyla sınıflandırma yapmıştır. Abdel-Khalik – El-Sheshai ise sadece ayırma analizinin geçerlilik çalışmasında % 57,5 doğru sınıflandırma başarısı elde edebilmiştir.⁷⁹ Söz konusu çalışmada insana dayalı modeller ayırma analizine göre daha düşük doğru sınıflandırma oranı ürettiği için dikkate alınmamışlardır.

⁷⁹ A.g.e.

İkinci olarak insana dayalı karar modellerini kullanan Libby, Trotman ve Zimmer çalışması uzman sistem kullanılarak tekrarlanmıştır. Libby, Trotman ve Zimmer bireylerin ortalama öngörü başarısını %75,9, bireylerin verdikleri en iyi öngörü başarısını ise %86,6 olarak tespit etmiştir. Aynı örneklem verileri için ise ayırma analizinin başarısı %84,1'dir. Oysa söz konusu veriler üzerinde uzman sistemin başarısı %100 olmuştur. Sonuçta, çalışmada uzman sistemin ayırma analizinden, kişilerin ve grupların verdiği kararlardan daha başarılı olduğu sonucuna varılmıştır.⁸⁰

Uzman sisteme dayalı olarak finansal sağlık değerlendirmesi ve finansal başarısızlığın öngörülmesinin etkin olarak yapılabileceği sonucuna varan başka bir çalışmada, kural tabanlı sistem, finansal başarısızlıktan önceki 7-13 ve 13-18 ay öncesinde geleneksel modellere göre daha üstün sonuçlar elde ettiği görülmüştür.⁸¹

3.1.3.2. Yapay Sinir Ağı Teknolojisini Kullanan Modeller

Yapay zeka teknolojileri içinde son yıllarda çok ilgi uyandıran bu bilgişlem teknolojisi, istatistik teknikler gibi varsayımlara gereksinim duymamakta ve sınıflandırma, öngörü konusunda oldukça iyi sonuçlar üretmektedir. Çalışmanın üçüncü bölümü bu teknolojiye ve bu teknolojinin finansal başarısızlığın öngörmesinde kullanımı konusuna ayrılmıştır.

⁸⁰ A.g.e. p.1413.

⁸¹ ELMER Peter J. – BOROWSKI David M., "An Expert System Approach to Financial Analysis: The Case of S&L Bankruptcy", *Financial Management*, (Autumn 1988) , pp.66-75.

3.2.FİNANSAL BAŞARISIZLIĞIN ÖNGÖRÜLMESİNDE KULLANILAN

MATEMATİKSEL - İSTATİSTİKSEL MODELLERİN DEĞERLENDİRİLMESİ

Finansal başarısızlığın öngörülmesinin sağlayacağı yararlar araştırmacıları bu konu üzerine çekmiş ve bu alanda oldukça geniş sayılabilecek bir yazın birikimi oluşmuştur. Yazın incelendiğine finansal başarısızlığın öngörülmesinde çok değişkenli modellerin daha fazla yer aldığı görülmektedir. Ancak çok değişkenli modellerin geliştirilmesinde kullanılan tekniklerden ve kısmen de modellerin geliştirilmesinde değişken olarak kullanılan finansal oranlardan kaynaklanan sorunlar bulunmaktadır. Çok değişkenli modellerin geliştirilmesinde çok değişkenli ayırma analizi en sık kullanılan tekniklerden olduğu için, ayırma analizi tekniğinin kullanılmasından kaynaklanan sorunları temel alan bir yaklaşım izlenecektir. Ancak diğer tekniklerinin kullanılmasından ortaya çıkan sorunlar da gerektiğinde belirtilecektir.⁸²

Bu sorunları şu şekilde sıralamak olurludur :⁸³

- i. Finansal oranların dağılımının çok boyutlu normal dağılım özelliğini göstermemesi
- ii. Değişken olarak kullanılan finansal oranların çoklu korelasyon göstermesi
- iii. Değişkenlerin dönemsel olarak istikrar göstermemesi, negatif değer veya hiç

⁸² Yazında söz edilen bazı istatistik sorunlar günümüzde bilgisayar programları tarafından çözülmüş bulunmaktadır. Örneğin değişkenlerin önemliliğinin belirlenmesi, ayırma fonksiyonunun geçerliliğinin test edilmesi. Ayrıca Bkz: AKGÜL Aziz, *Tıbbi Araştırmalarda İstatistiksel Analiz Teknikleri:SPSS Uygulamaları*, Yüksek Öğretim Kurulu Matbaası, Ankara, 1997

⁸³ AKTAŞ, A.g.e., ss.75-85; EISENBEIS Robert A., "Pitfalls in the Application of Discriminant Analysis in Business, Finance and Economics", *The Journal of Finance* , V.:XXXII N.:3, (June 1977), pp.875-900.

değer bulunmaması sorunu,

- iv. Örneklemin evreni temsil etmemesi sorunu,
- v. Örneklem birimlerinin eşleştirilmesi sorunu,
- vi. Grupların sapma matrislerinin eşit olmaması,
- vii. Modelin büyüklüğü (çok sayıda değişken içeren model) sorunu,
- viii. Bağımlı değişkeni oluşturan grupların tanımlanması (ayrıştırılması) sorunu,
- ix. Önsel olasılık ve yanlış sınıflandırma maliyetinin belirlenememesi sorunu,
- x. Geçerlilik sorunu.

Yukarıdaki sıralanan sorunları büyük bir kısmı model kurmak için tercih edilen matematisel - istatistiksel tekniğin varsayımlarının veya tekniğin uygulama biçiminin finansal başarısızlığın öngörülmesi alanına uygun olmamasından kaynaklanmaktadır.⁸⁴

3.2.1. Finansal Oranların Dağılımının Çok Değişkenli Normal Dağılım Özelliğini Göstermemesi Sorunu

Çok boyutlu ayırma analizi ve çoklu regresyon analizi çok değişkenli istatistik teknikler içinde verilerin çoklu normal dağılım özelliği gösterdiği varsayımına dayanan iki tekniktir. Ancak ekonomik ve finansal verilerin normal dağılım gösterdiği son derece nadir

⁸⁴ AKTAŞ ilk üç sorun dışındakileri istatistik tekniklerle ilgili sorun olarak nitelendirmektedir. AKTAŞ, A.g.e., s.81-82.

durumlardır. Yapılan bir çalışmada Toplam Borç/ Toplam Varlıklar dışındaki hiçbir oranın normal dağılmadığı gözlenmiştir.⁸⁵ Değişkenlerin normal dağılmadığı bilindiği halde, bu teknikleri kullanan araştırmacıların verilerin bu varsayımı gerçekleyp gerçeklemediğinin test ettiğine çoğu araştırmada rastlanmamıştır.⁸⁶ Bunun temel nedeni ise değişkenlerin normal dağılım gösterip göstermediği konusunda testler bulunmasına rağmen, henüz pratik olarak verilerin normal dağılıp dağılmadığını inceleyen herhangi bir bilgisayar programının olmamasıdır.⁸⁷ Nitekim araştırmacıların çoğu bu varsayımı ya görmezlikten gelmişler ya da verilerin çoklu normal dağılmadığı konusundaki eksiklikleri dile getirerek, çalışmanın sonucunda modelin doğruluk oranının yüksek olmasından dolayı ayırma analizinin varsayımın çiğnenmesine karşı güçlü (robust) bir teknik olduğunu idda etmişlerdir.⁸⁸ Bazı yazarlar ise finansal oranların normal dağılmaması sorununu gidermek için değişik dönüştürme teknikleri uygulamıştır veya ayırma analizinin sonuçlarını çoklu normal dağılım varsayımına gerek duymayan Logit veya Probit ile karşılaştırmıştır.⁸⁹ Oysaki yapılan bir çalışmada finansal oranların çarpık olmasının bir nedeni olan veri yığınınındaki uç değerlerin atılmasının çarpıklığı gidermediği; ayrıca çarpıklığı düzeltmek için yaygın olarak kullanılan endüstri ortalaması değerlerine bölmenin de, yanlışlıklara yol açabileceği belirtilmiştir.⁹⁰ Ancak ayırma analizinin,

⁸⁵ DEAKIN Edward B., "Distributions of Financial Accounting Ratios : Some Emprical Evidence", *Accounting Review*, (January 1976), pp. 90-96.

⁸⁶ ALTMAN, "Financial Ratios, Discriminant...", pp.589-609.; GENTRY-NEWBOLD-WHITFORD, A., "Classifying Bankrupt Firms....", pp.146-160.; AZIZ-EMANUEL-LAWSON, A.g.e., pp.419-437.; DEAKIN, "A Discriminant Analysis....", pp.167-179.

⁸⁷ AKTAŞ, A.g.e., s.76. EISENBEIS, A.g.e., p.875.

⁸⁸ BOOTH Peter J. , " Decomposition Measures and the Prediction of Financial Failure", *Journal of Business Finance & Accounting*, V.:10 N.:1 (1983), pp.67-82.

⁸⁹ CASEY- BARTCZAK, A.g.e., pp.384-401.; GENTRY-NEWBOLD-WHITFORD, A., "Classifying Bankrupt Firms....", pp.146-160.; AZIZ- EMANUEL - LAWSON, A.g.e., pp.419-437.

⁹⁰ SO Jacky C., " Some Emprical Evidence on the Outliners and Non-Normal Distribution of Financial Ratios", *Journal of Business Finance & Accounting*, V.:14, N.:4, (1987), pp.483-496.

çoklu normal dağılım özelliğinin bulunmadığı durumlarda da güçlü olduğu yönündeki bulgular⁹¹ ve bazı araştırmacıların değişkenlerin tek tek normal dağılması durumunda verilerin çoklu normal dağılacığı şeklindeki varsayımlar da⁹² her zaman doğrulanmamaktadır.⁹³

Verilerin çoklu normal dağılım göstermemesi, önemlilik testi ve özellikle hata oranının belirlenmesi için bir yanlışlık yaratmaktadır.⁹⁴ Bir başka ifadeyle modelde kullanılan değişkenlerin saptanmasında yanlışlığın sonucu olarak, gerçekte önemli olan bir değişken önemsiz hale gelebilmektedir. Hata oranının yanlışlığı ise geçerlilik testinin duyarlılığını azalacaktır.

Bu sorunlar ayırma analizi ve çoklu regresyonun her ikisi içinde geçerli iken, özellikle kuadratik ayırma analizi tekniğinin çoklu normal dağılımdan uzaklaşmalara karşı çok daha duyarlı olduğu bilinmektedir.⁹⁵

3.2.2. Değişken Olarak Kullanılan Finansal Oranların Çoklu Korelasyon Göstermesi Sorunu

Çok değişkenli tekniklerde, modelin katsayıları konumundaki değişkenlerin kendi aralarında göstermiş oldukları korelasyon ilişkisine çoklu korelasyon adı verilmektedir. Finansal başarısızlığın öngörülmesinde kullanılan finansal oranlar arasında çoklu korelasyon

⁹¹ EISENBEIS, A.g.e., "Pitfalls in...", p.876.

⁹² KARELS Gordon V.- PRAKASH, "Multivariate Normality and Forecasting of Business Bankruptcy", *Journal of Business Finance & Accounting*, V.:14, N.:4 (Winter 1987), pp.573-593.

⁹³ BARNES Paul, " Methodological Implacations of Non-Normality Distributed Financial Ratios", *Journal of Business Finance & Accounting*, V.:9, N.:1, (1982), pp.51-60.

⁹⁴ A.g.e.

⁹⁵ AKTAŞ, A.g.e., s.77.

fazlasıyla bulunmaktadır. Bunun nedenlerinden birincisi bir çok oranın pay veya paydasında kullanılan değer, diğer oranların hesaplanmasında da kullanılıyor olmasıdır; ikinci olarak satışlar ve satılan malın maliyeti gibi bazı kalemlerin işletme işleyişi içinde doğal olarak birlikte hareket etmeleridir.⁹⁶

Çoklu korelasyon özellikle çok değişkenli analiz tekniklerinin değişkenlerin anlamlılık testlerinde, hangi değişkenlerin anlamlı olduğunun ve dolayısıyla boyut indirgemedede hangi değişkenlerin kullanılacağıın tespit edilmesinde sorun yaratmaktadır. Çoklu korelasyonun, çoklu regresyonun katsayılarının belirlenmesinde herhangi bir etkisi olmamaktadır. Ayrıca ayırma analizinde herhangi bir önemlilik testi olmadığı için bu durum, çoklu korelasyonun ayırma analizinde sapma matrisinin tersini almasına engel olacak ölçüde yüksek olmadığı sürece, herhangi bir sorun yaratmayacaktır.⁹⁷ Çoklu korelasyon olması veya çoklu korelasyonun modelin kurulmasında dikkate alınması, modelin tahmin gücünü arttırabilmektedir.⁹⁸ Ancak değişkenler arasında çoklu korelasyon bulunması sadece belli örneklem için geçerli modeller üretilmesi gibi bir olumsuzluğa da neden olduğu gözden kaçırılmamalıdır.⁹⁹

3.2.3. Değişkenlerin Dönemsel Olarak İstikrarsızlığı Sorunu

Çoklu regresyon analizinin varsayımlarından birisi sabit varyans varsayımıdır

⁹⁶ A.g.e, ss.78-79.

⁹⁷ ALTMAN Edward I., EISENBEIS Robert A., "Financial Applications of Discriminant Analysis : A Clarification", *Journal of Financial and Quantative Analysis*, (March 1978), pp.185-188.

⁹⁸ MENSAH Yaw M., " An Examination of Stationary of Multivariate Bankruptcy Prediction Models: A Methodological Study", *Journal of Accounting Research*, V.:22, N.:" (Spring 1984), pp.380-395.; AKTAŞ, A.g.e., ss.78-79.

⁹⁹ CHEN Kung H.- SHIMERDA Thomas A., " An Empirical Analysis of Useful Financial Ratios", *Financial Management*, (Spring 1981), pp.51-60.

(heteroscedasticity). Bağımsız değişkendeki değişmelerin, bağımlı değişkenin dağılımını etkilemediği durumda sabit varyanstan söz etmek mümkündür.¹⁰⁰ Finansal oranların zaman içinde gösterdikleri korelasyon ise finansal oranlarda sabit varyans eksikliği sonucunu doğurmaktadır. Sabit varyans eksikliğinin bir nedeni, finansal oranların başarısız olmayan işletmeler için belli düzeyde kalmasıdır, ikinci olarak ekonomik gelişmeler tüm işletmeleri aynı ölçüde etkilemektedir.¹⁰¹ Sabit varyans varsayımının gerçekleşip gerçekleşmediğinin araştırmanın kolay yolu için grafikte bağımlı ve bağımsız değişkenlerin serpmme grafiği incelenir. Eğer noktalar grafikte dengeli olarak dağılmamış, yani dikey olarak bazen birbirine çok yakın, bazen de birbirinden uzak ise bu durumda sabit varyanstan şüphe etmek gerekir.¹⁰² Sabit varyans eksikliği modelin tahmin gücünü azaltan bir istikrarsızlık unsurudur.¹⁰³ Finansal oranların istikrarının ölçülmesinde kullanılan diğer ölçütler ise oranların standart sapması, tahminin standart hatası ve varyasyon katsayısı gibi dağılım ölçütleridir. Özellikle başarısız işletmelerin finansal oranlarının istikrarsızlık gösterdiği ve doğrusal ayırma analizinin öngörü başarısını önemli ölçüde olumsuz etkilediğini ortaya koyan çalışmalar bulunmaktadır.¹⁰⁴ Ancak özellikle değişkenlerin istikrarını bozucu etkisi olduğu düşünülen enflasyonun, modellerin öngörü başarısına üzerindeki etkisi konusunda çelişik araştırma

¹⁰⁰ AKGÜL, A.g.e., s.468.

¹⁰¹ AKTAŞ, A.g.e., s.79.

¹⁰² AKGÜL, A.g.e., s.468.

¹⁰³ AKTAŞ, A.g.e., s.80.

¹⁰⁴ RICHARDSON Frederick M.- DAVIDSON Lewis F., " On Linear Discrimination With Accounting Ratios", *Journal of Business Finance & Accounting*, V.:11, N.:4 (Winter 1984), pp.511-525.

sonuçları vardır. Bazı araştırmalar enflasyonun ayırma analizinin genel hata oranıyla başarısız olmayan işletmeleri sınıflandırma hatasına etkisi olmadığı ¹⁰⁵, bazıları ancak başarısız işletmeleri sınıflandırma hatasında ve hatalı sınıflandırma maliyetinde, fiyatlar genel seviyesine göre düzeltilmiş verilerle daha iyi sonuçlar ürettiği yönündedir. ¹⁰⁶ Bazı araştırmalar ise modellerin doğruluğunun ve yapısının değişik ekonomik ortamlar, hatta aynı ekonomik ortamda olan değişik endüstriler için dahi farklılık gösterdiği yönündedir ¹⁰⁷. Oranların gösterdiği istikrar konusunda, yukarıda özetlenmeye çalışıldığı gibi birbiriyle çelişen bulguların bulunması, istatistik teknikler kullanılırken, sabit varyans varsayımıyla hareket edilmesini güçleştirmektedir.

Net işletme sermayesi eksikliğinde olduğu gibi bazı oranların negatif olması finansal oranlarla çalışırken karşılaşılabilecek bir diğer sorundur. ¹⁰⁸ Bu durumda verilere müdahale edilerek bazı düzeltmeler yapılmaktadır. Ayrıca finansal başarısızlık araştırmalarında sıklıkla karşılaşılan bir sorun da veri eksikliğidir. ¹⁰⁹ Finansal başarısızlığa uğramış işletmelerin verilerinin bulunması işletmeler faaliyetlerine son vermiş ise oldukça zordur. Araştırmaların çoğunda bulunan verilerdeki eksiklikten dolayı örnekleme giren birim sayısı önemli ölçüde azalmaktadır.

¹⁰⁵ NORTON Curtis L.-SMITH Ralph E., "A Comparison of GERALD Price Level and Historical Cost Financial Statement in Prediction of Bankruptcy", *The Accounting Review*, V.:LIV N.:1 (January 1979), pp.72-87.

¹⁰⁶ KETZ, Edward J. "The Effect of General Price-Level Adjustments on the Predictive Ability of Financial Ratios", *Journal of Accounting Research*, V:16 (Supplement 1978), pp.273-284.

¹⁰⁷ MENSAH, A.g.e., pp.380-395.

¹⁰⁸ AKTAŞ, A.g.e., s.80.

¹⁰⁹ ZMIJEWSKI Mark E., "Methodological Issues Related to the Estimation of Financial Distress Prediction Models", *Journal of Accounting Research*, V.:22 (Supplement 1984), pp.59-81.

3.2.4. Örneklem Evreni Temsil Etmemesi Sorunu

Finansal başarısızlığın öngörülmesinde kullanılan örneklerle iki temel sorun yaşanmaktadır. Birincisi daha önce belirtilen eksik veri sorunudur. İkincisi ise örneklemin evreni temsil etmemesi sorunudur. Finansal başarısızlığın öngörülmesi çalışmalarında birimler, işletmenin başarısız veya başarısız olmayan şeklindeki modelin bağımlı değişken dikkate alınarak toplanmaktadır. Bu örneklem oluşturma konusunda teorik yaklaşımlara ters düşen bir tutum olmasına rağmen, örnekleme gelecek verilerin bulunması zorluğundan dolayı finansal başarısızlık alanındaki bir çok çalışmada izlenen bir yol durumundadır. Gerçek hayatta başarısız olan işletme oranı %0,75'i aşmazken, bu oran örneklerde %50'ye kadar çıkmaktadır.¹¹⁰ Doğal olarak araştırma sonuçları, örneğin ayırma analizi tekniğinde kullanılan önsel olasılıklarda olduğu gibi, örneklemden etkilenmektedir. Örneklem büyüklüğü de, istatistik tekniğinin seçilmesini ve modelin öngörü yeteneğini belirleyen önemli bir etkidir. Kuadratik ayırma analizi, Logit ve Probit teknikleri örneklem sayısının az olduğu durumlara karşı doğrusal ayırma analizinden ve çoklu regresyondan daha duyarlıdır.¹¹¹ Bu örneklemin küçük olduğu durumda modelin öngörü yeteneğinin düşmesi anlamına gelir.

3.2.5. Örneklem Birimlerinin Eşleştirilmesi Sorunu

Finansal başarısızlık yazınında eşleştirilmiş örneklem birimleri kullanıldığı çalışmaların sayısı oldukça fazladır. Önceden de belirtildiği gibi değişkenlerin istikrarını etkileyen çok sayıda etken bulunmaktadır. Örneğin genel ekonomik duruma ilişkin enflasyon,

¹¹⁰ ZMIJEWSKI, A.g.e., p.60.

¹¹¹ AKTAŞ, A.g.e., ss.83-84.

para politikaları, milli gelirdeki değişiklikler ve endüstriyel farklılıklar gibi. Bu tür etkenlerin modellerin öngörüsü üzerindeki etkileri olacağı yönündeki önyargı, araştırmacıları bu etkenlerin değişkenler üzerindeki etkisini kontrol altına almak için başarısız işletmeler ile başarısız olmayan işletmeleri eşleştirmeye yöneltmiştir.¹¹²

Eşleştirilmiş örneklem birimi kullanılması, özellikle rassal örneklem almaya engel olması bakımından eleştirilmiştir. Bunun başarısız işletmelerin gerçekte olduğundan daha yüksek sıklıkla örneklemede yer almasına sebep olması, yanlış olarak başarısız işletmelerin daha küçük bir öngörü hatasıyla öngörülmesini sağlamaktadır, ancak modelin öngörü başarısına ve toplam sınıflandırma hatasına herhangi bir etkisi bulunmamaktadır. Hatta finansal başarısız işletmelerin daha düşük öngörü hata oranıyla öngörülmesi, başarısız işletmelerin hatalı öngörmenin maliyetinin daha yüksek olduğundan yararlıdır, denilebilir.¹¹³ Bu pragmatik yönü nedeniyle eşleştirilmiş örneklem kullanılması tercih edilmekle birlikte yazında eşleştirilmiş örneklem birimleri kullanmanın modellerin öngörü başarısını arttırdığı yönünde herhangi bir kanıt da bulunmamaktadır.¹¹⁴

3.2.6. Grupların Sapma Matrislerinin Eşit Olmaması Sorunu

Doğrusal ayırma analizinin önemli bir varsayımı da grupların sapma matrislerinin eşit olması varsayımdır. Bu varsayımdan uzaklaşma grup ortalamaları arasındaki farkın anlamlılık testlerini etkilediği gibi, modelin doğru sınıflandırma gücünü de olumsuz olarak

¹¹² AZIZ-EMANUEL-LAWSON, A.g.e.,p.422.

¹¹³ A.g.e.

¹¹⁴ KAREL-PRAKASH, A.g.e., p.587.;

etkilemektedir.¹¹⁵ Nitekim bazı yazarlar daha önceden doğrusal ayırma analizi tekniği kullanıyor iken, daha sonradan bu varsayıma gerek duymayan kuadratik ayırma analizini kullanmaya başlamışlardır.¹¹⁶ Ancak kuadrantik ayırma analizi tekniğinin çoklu normal dağılıma her durumda gereksinim duyduğu ve daha büyük örneklem kullanılması gerektirdiği gözden uzak tutulmamalıdır.

Grupların sapama matrislerinin eşit olmamasından kaynaklanan sorunların ortadan kaldırılması için kuadratik ayırma analizinin yanında, bu varsayıma gerek duymayan Logit ve Probit veya çoklu regresyon analizi kullanılabilir.¹¹⁷

3.2.7. Modelin Büyüklüğü Sorunu

İşletmelerin finansal durumunu ortaya koymak amacıyla oluşturulmuş çok sayıda değişken bulunmaktadır. Bütün değişkenlerin modelde yer alması, modellerin kullanımı güçleştirir. Ancak kullanılan değişkenlerin sayısı değişik yöntemlerle azaltılabilmektedir. Bu durum özellikle sapma matrislerinin eşit olmaması durumunda modelin öngörü gücünü olumsuz yönde etkileyebilmektedir.¹¹⁸ Ayrıca finansal başarısızlığın öngörülmesinde kullanılan modellerin geliştirilmesi sırasında yapılan boyut indirgeme işlemi sonucu bazı oranlar modelden dışlanmaktadır. Oysa ki, finansal analizde bazı oranların aldığı değer bazı işletmeler için sorun yaratırken; diğer bazı işletmeler için, başka oranların aldığı değerler nedeniyle sorun yaratmayabilir.

¹¹⁵ EISENBEIS, A.g.e., p.878.

¹¹⁶ ALTMAN- LORIS ,A.g.e., pp.1201-1217.

¹¹⁷ AKTAŞ, A.g.e., s.87.

¹¹⁸ A.g.e., s.89.; EISENBEIS, A.g.e., pp.885-887.

3.2.8. Bağımlı Değişkeni Oluşturan Grupların Tanımlanması Sorunu

Ayırma analizinin bir varsayımı da incelenen grupların bir birinden farklı ve tanımlanabilir olduğudur. Fakat çalışmaların çoğunda bu varsayımın çiğnendiği görülmektedir.¹¹⁹ Finansal başarısızlığın öngörülmesinde kullanılan verilerdeki işletmeler tam başarılı sayılmayacakları gibi tam başarısız olarak da kabul edilmez durumdadır. Bu durum bağımlı değişkenin kesikli değil sürekli olduğunu ifade etmektedir. Böyle bir durumda Logit veya çoklu regresyon tekniğinin kullanılması önerilmektedir.¹²⁰

Finansal başarısızlığın sınıflandırılabilceği daha fazla grup tanımlamak ise daha önce belirtildiği gibi sadece hatalı sınıflandırma yapılabilecek grup sayısını arttırmaktan başka bir işe yaramamaktadır.¹²¹

3.2.9. Önsel Olasılık ve Yanlış Sınıflandırma Maliyetinin Belirlenememesi Sorunu

Ayırma analizi tekniğinin sınıflandırma kuralları, evrenden alınan değişik örneklerde herhangi bir olayın olma önsel olasılığını ve bazı sınıflandırma hatalarının diğerlerine oranla daha önemli olduğu durumlar için, hatalı sınıflandırma maliyetine ilişkin bilgileri de içermektedir. Çünkü ayırma analizi tekniği, yanlış sınıflandırma maliyetini minimize etmek üzere tasarlanmış bir istatistik tekniktir. Eğer önsel olasılıklar doğru bir şekilde kullanılmamışsa sınıflandırma hatası oldukça büyük olmaktadır. Evrene ait oranlar bilinemediği durumda önsel olasılık olarak örneklem oranları, sadece örneklem rassal olarak

¹¹⁹ EISENBEIS, A.g.e., p.887.

¹²⁰ A.g.e., p.888.;TATLIDİL, A.g.è., s.215.

¹²¹ HING - LAU, A.g.e., p.136.

oluşturulmuş ise kullanılır. Ancak eşlemeli örnekleme olduğu gibi örneklemin rassal olmadığı durumda bulunacak örnek oranı, sadece bu örnekleme için geçerli önsel olasılıklar olacaktır.¹²² Nitekim finansal başarısızlık alanındaki örneklemlerin çoğunda, önsel olasılık olarak, eşlemeli örnekleme kullanıldığı için bu oran %50-%50 kullanılmıştır.

Önsel olasılıkların zaman serisi çerçevesinde kullanımında da sorunlar çıkmaktadır. Çünkü bir dönem için kullanılan oranlara ilişkin gözlemler, gelecek dönem içinde kullanılmaktadır. Oysaki gruplara ilişkin olarak birimlerin ortaya çıkış oranları, dönemde döneme değişmektedir. Bu durum değişik dönemlere ait gözlem değerlerinin bir araya getirildiği durumlarda da söz konusudur. Veri sıkıntısından dolayı yapılan bu uygulamada hangi oranın önsel olasılık için kabul edileceği bilinmemektedir.¹²³

3.2.10. Geçerlilik Sorunu

Elde edilen modelin örnekleme üzerindeki öngörü gücüyle modelin gerçek öngörü gücü arasında farklılık olabilmektedir. Bu durum iki nedenden kaynaklanmaktadır. Birincisi her örnekleme olayında olduğu gibi, kaçınılmayan örnekleme hatasıdır. İkincisi ise örnek üzerinde en iyi sonucu elde etmek için bazı değişkenler aşırı anlamlı bulunurken, gerçekte anlamlı olan değişkenlerden bazıları anlamsız bulunarak, modelin boyutları indirgenirken dışlanmalarıdır.¹²⁴

¹²² EISENBEIS, A.g.e., pp.889-890.

¹²³ A.g.e., pp.891-892.

¹²⁴ AKTAŞ, A.g.e., s.92.

Bu durumun önüne geçmek için geçerlilik testlerinin yapılması gerekmektedir. Günümüzde bu geçerlilik testleri istatistik bilgisayar programları tarafından kolaylıkla yapılmaktadır.¹²⁵ Ayrıca elde edilmiş olan modelin yeni veriler üzerinde kullanılmasıyla da geçerlilik testi yapılmış olmaktadır. Ancak bu test daha fazla verinin kullanımını gerektirmektedir.¹²⁶

¹²⁵ AKGÜL, A.g.e.,s.564.

¹²⁶ AKTAŞ, A.g.e., s.93.



DÖRDÜNCÜ BÖLÜM

YAPAY SINIR AĞI TEKNOLOJİSİ VE FİNANSAL BAŞARISIZLIĞIN ÖNGÖRÜLMESİNDE KULLANIMI

DÖRDÜNCÜ BÖLÜM

YAPAY SİNİR AĞI TEKNOLOJİSİ VE FİNANSAL BAŞARISIZLIĞIN ÖNGÖRÜLMESİNDE KULLANIMI

4.1.YAPAY SİNİR AĞI

Öğrenme ve çevreye uyabilme yeteneğinin koşulu zeki olmaktır. Düşünme yeteneği ve zeka, beynin ve merkezi sinir sisteminin görevidir. Beyini hasara uğramış birçok kişide öğrenme ve çevreye uyumda bazı sorunlar olduğu gözlemlenmiştir.¹

Beyin neuron adı verilen birçok sinir hücresinin bir araya gelmesinden oluşmaktadır. İnsan bünyesinde yer alan tüm diğer hücreler belli bir süre sonunda ölürler ve yerlerine yenisi üretilirken neuronlar kendiliklerinden ölmezler. Bu durum belki de bilgilerin nasıl kalıcı olduğunu da açıklamaktadır. İnsan vücudunda yaklaşık olarak 10^{11} neuron bulunmaktadır.²

¹ TRIPPI Robert R.- TURBAN Efraim, *Neural Network in Finance and Investing*, Irwin Professional Pub., Chicago,1996, p.4.

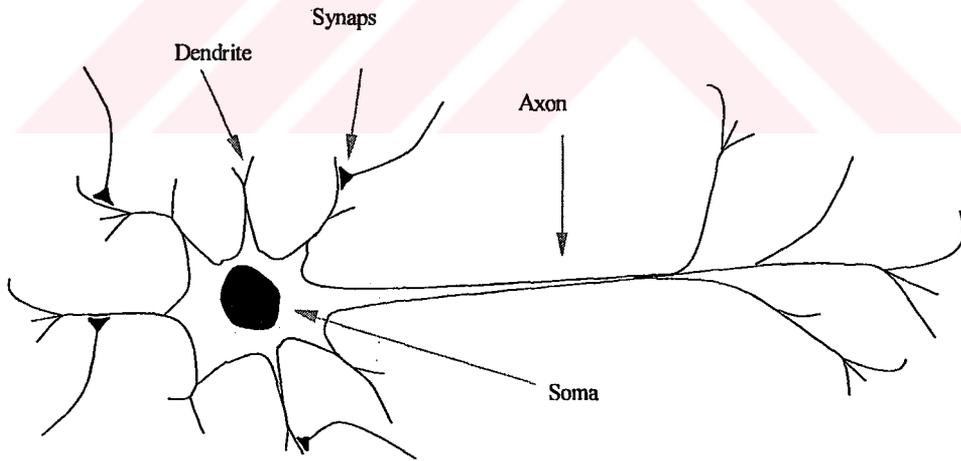
² KOHONEN Teuvo, "An Introduction to Neural Computing",*Neural Networks*, V:1 (1988), p.4.

Beyinde yer alan sinir hücreleri işlevlerine göre çevreden gelen girdileri sinir sistemine girişini sağlayan duyuşal sinir hücreleri (afferent and sensory neurons), sinyalleri kaslara ve diđer organlara ileten motor sinir hücreleri (motor neurons) ile sinir sisteminin çok büyük bir bölümünü oluşturan ara sinir hücrelerinden (interneuronal neurons) oluşur. Ara sinir hücrelerinin görevi bilgilerin işlenmesini ve sinyallerin bir yerden bir yere yayılmasını sağlamaktır.³

Sinir hücreleri bir grup halinde işlev gördüklerinde ağ (network) olarak adlandırılırlar ve böyle bir grupta binlerce neuron bulunur. Beyin aslında, bu sinir ağlarının (neural network) toplamı olarak görülmektedir.⁴

Neuron yapısının, bilginin işlenmesinde önemli etkisi vardır (Şekil 3.1).

Şekil 4. 1 :Biyolojik neuron ve yapısı



³ SCHALKOF Robert J. *Artificial Neural Networks*, The McGraw-Hill Companies, Inc., Newyork,1997, pp.62-63.

⁴ TRIPPI-TURBAN, A.g.e.,p.4.

Birbiriyle bağlantılı iki neuronun axon, dentrite, synaps ve soma olma üzere dört önemli bölümü bulunmaktadır.⁵

Axon: Hücre çıktısını göndermeye yarayan uzantısıdır. Bir hücrenin tek bir axon uzantısı bulunur. Ancak bu axon uzantıdan çıkan çok sayıda uzantı ve bunların ucunda synapstik bağlantılar bulunur.

Dentrites : Neuronun ağaç köküne benzeyen, görevi hücreye girdilerin sağlanması olan uzantılardır.

Synapse: synapslar, sinir hücrelerindeki axonlarının, diğer sinir hücreleri ve/veya onların dentriteleri üzerinde sonlanan özelleşmiş bağlantı noktalarıdır. Bu bağlantı noktalarının görevi axondaki elektriksel iletinin diğer hücrelere aktarılmasıdır. Bu bağlantı noktalarında iletiler elektro-kimyasal süreçlerle diğer hücrelere geçirilir. Synapslar bağlandıkları dentrite veya neuronda bölgesel olarak elektrik kuvvetini pozitif veya negatif yönde etkileyebilme yeteneğine sahiptirler. Böylelikle bir neuronun diğerini etkileyebilmesi söz konusu olmaktadır (Şekil 4.1).⁶

Soma : Bir neuronun gövdesine soma adı verilir. Soma nucleus adı verilen hücre çekirdeğini içermektedir. Hücrenin yaşamasını sağlayan işlevleri görür. Synapslar aracılığıyla dentriteslere geçirilen iletiler birleşerek axon üzerinde elektriksel bir çıktı oluştururlar. Bu çıktının olup olmayacağı veya çıktının elektriksel olarak yoğunluğu, synapsların etkileri

⁵ SCHALKOFF, A.g.e., p.63.

⁶ CICHOCKI Andrzej - UNBEHAVEN Rolf, **Neural Networks for Optimization and signal Processing**, John Wiley and Sons, Gb. Stuttgart, 1993, pp.39-40.

sonucu hücreye gelen tüm girdilerin, toplam değeri tarafından belirlenmektedir. ⁷ Somaya gelen girdilerin ağırlıklı toplamı axon üzerinde çıktı oluşturacak değere ulaştığında, bu değere "eşik değeri" adı verilmektedir ve neuron ateşlendi (fired) olarak ifade edilmektedir. Bu şekilde girdiler neuron tarafından değerlendirilerek çıktıya dönüştürülmüş olur. ⁸

İnsan beyninin ve düşünme yeteneğinin taklit edilmesi isteği sanıldığı gibi aksine çok eski zamanlarda var olmuş bir istektir. İnsan beyni ve düşünebilme yeteneğine ilişkin ilk açıklayıcı teori geliştirme denemeleri Antik Yunan düşünürleri olan Plato (İ.Ö. 427-327) ve Aristoteles'e (İ.Ö. 384-322) kadar uzanmaktadır. Daha sonra ise Descartes (1596-1650) insanın düşünme yeteneğiyle ilgilenen 18. yüzyıl düşünürü olmuştur. ⁹

Yapay sinir ağlarının dayandığı ilk hesaplama modelinin temelleri 1940'ların başında araştırmalarına başlayan W.S. McCulloch ve W.A. Pitts'in, 1943 yılında yayınladıkları bir makaleyle atılmış oldu. Daha sonra 1954 yılında B.G. Farley ve W.A. Clark tarafından bir ağ içerisinde uyarılara tepki veren, uyarılara adapte olabilen model oluşturulmuştur. 1960 yılı ise ilk neural bilgisayarın ortaya çıkış yılıdır. ¹⁰ 1963 yılında basit modellerin ilk eksiklikleri fark edilmiş, ancak başarılı sonuçların alınması 1970 ve 1980'lerde termodinamikteki teorik yapıların doğrusal olmayan ağların geliştirilmesinde kullanılmasına kadar gecikmiştir. 1985 yapay sinir ağlarının oldukça tanındığı, yoğun araştırmaların başladığı yıl olmuştur. ¹¹

⁷ De WILDE Philippe, **Neural Network Models**, Second ed., Springer, London, 1997, pp.53-61.

⁸ KORN Granino, **A Neural Network Experiments on Personal Computers and Workstations**, A Bradford Book The MIT Press, London, ?, p.4.

⁹ KOHONEN, A.g.e.,p.3.

¹⁰ A.g.e.

¹¹ MEHRA Pankaj- WAH W. Benjamin, **Artificial Neural Networks : Concepts and Theory**, IEEE Computer Society Press, Washington, 1992, pp.4-5.

Yapay sinir ağının genel bir tanımı yapılması gerekirse "Yapay Sinir Ağı insan beyninin çalışma ve düşünebilme yeteneğinden yola çıkılarak oluşturulmuş bir bilgi işlem teknolojisidir."¹² Yapay sinir ağının işleyiş özelliklerine dayanan ikinci tür tanımı ise ilk ticari yapay sinir ağının geliştiricisi olan Dr. Robert HECHT-NIELSEN'e ait bir tanımdır: "yapay sinir ağı dışarıdan gelen girdilere dinamik olarak yanıt oluşturma yoluyla bilgi işleyen, birbiriyle bağlantılı basit elemanlardan oluşan bilgiişlem sistemidir."¹³ Bu tanıma yakın bir tanımda yapay sinir ağı yazınında çok tanınan Teuvo KOHONEN'e ait bir tanımdır : " Yapay sinir ağları paralel olarak bağlantılı ve çok sayıdaki basit elemanın, gerçek dünyanın nesnelere biyolojik sinir sisteminin benzeri yolla etkileşim kuran olan, hiyerarşik bir organizasyonudur."¹⁴

4.2.YAPAY SİNİR AĞI MODELİ

Yapay sinir ağıyla aslında biyolojik sinir ağının bir modeli oluşturulmak istenmektedir. Bu amaçla da geleneksel bilgisayar donanım ve yazılımlarından yararlanılabileceği gibi YSA oluşturmak amacıyla geliştirilmiş paralel işlem yapan özel bilgisayarlardan da yararlanılabilmektedir.

4.2.1. Yapay Sinir Ağının Bileşenleri

Yapay sinir ağının yapısında neuron, bağlantılar ve ağırlıklar olmak üzere üç bileşeni bulunmaktadır.

¹² TRIPPI-TURBAN, A.g.e., p.4.

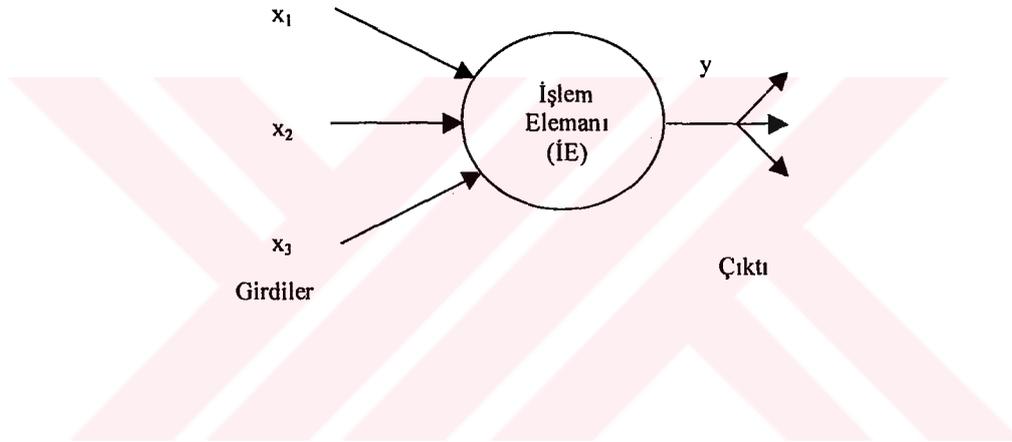
¹³ CAUDILL Maureen, "Neural Networks Primer Part I", AI Expert, December 1987, pp.47.

¹⁴ KOHONEN, A.g.e., p.4.

4.2.1.1. Neuron

Biyolojik sinir ağlarında olduğu gibi yapay sinir ağlarında da temel unsur yapay neurondur (artificial neuron). Yapay neuron, bir ağın temel işlem elemanıdır. Ağ içinde yer alan tüm neuronlar bir veya birden fazla girdi alırlar ve tek bir çıktı verirler. Bu çıktı yapay sinir ağının dışına verilen çıktılar olabileceği gibi başka neuronlara girdi olarak da kullanılabilirler (Şekil 4.2).

Şekil 4. 2 : Yapay Neuron (artificial neuron)

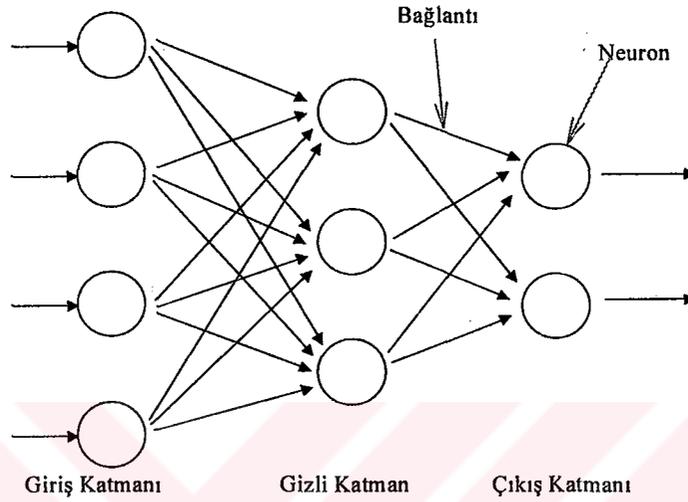


4.2.1.2. Bağlantılar

Yapay neuronların birbirleriyle bağlantılar aracılığıyla bir araya gelmeleri yapay sinir ağını oluşturmaktadır (Şekil 4.3).¹⁵

¹⁵ VEMURI V. Rao, *Artificial Neural Networks: Concepts and Control Applications*, IEEE Computer Society Press, Los Alamitos, California, 1992, p.42.

Şekil 4.3 : Yapay Sinir Ağı Modeli



Neuronların aynı doğrultu üzerinde bir araya gelmeleriyle katmanlar oluşmaktadır. Katmanların değişik şekilde bir birleriyle bağlanmaları değişik ağ mimarilerini doğurur.

Yapay sinir ağında ilk katman girdi katmanıdır ve dışarıdan verilerin yapay sinir ağına alınmasını sağlar. Diğer katman ise çıktı katmanıdır. Bu katmanda bilgilerin dışarıya iletiildiği katmandır. Girdi ile çıktı katmanları arasında katman varsa bu katmanlara gizli katman (hidden layer) adı verilir. Bir yapay sinir ağında gizli katman olması gerekmediği gibi, birden fazla gizli katman da bulunabilir.¹⁶ Yazında hemen hemen tüm çalışmalarda girdi katmanı, girdilerin ağına girmesinde bir kapı işlevi görmesi nedeniyle katman olarak sayılmamaktadır.

¹⁶ VEMURI, A.g.e., p.42.

Bundan dolayı girdi katmanıyla birlikte 3 katmandan oluşan ağ iki katmanlı ağ olarak kabul edilir.

4.2.1.3. Ağırlıklar

Bir yapay sinir ağındaki en önemli unsurlardan biri de bağlantılardır. Neuronların bir birilerine veri aktarımını sağlayan bağlantılar aynı zamanda bir ağırlık (weight) değerine sahiptirler. Ağırlıklar bir neuronda girdi olarak kullanılacak değerlerin göreceli kuvvetini (matematiksel katsayısını) gösterir. Yapay sinir ağı içinde girdilerin neuronlar arasında iletimini sağlayan tüm bağlantıların farklı ağırlık değerleri bulunmaktadır. Böylelikle ağırlıklar her işlem elemanının her girdisi üzerinde etki yapmaktadır.¹⁷

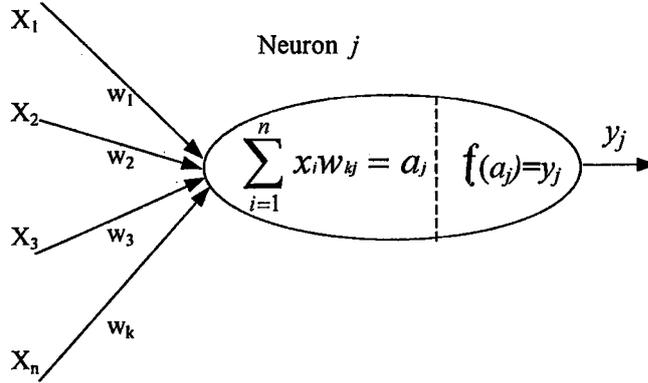
4.2.2. Yapay Sinir Ağının İşleyişi

Yapay sinir ağı işleyişi kabaca incelenecek olursa, girdiler, girdi katmanından ağa girer, bağlantılar aracılığıyla çıktı katmanına ulaşıncaya kadar her neuronda işlenerek bir neurondan diğerlerine geçirilir.

Yapay sinir ağının bu işleyişinde ve öğrenme yeteneğini ortaya çıkmasında neurona ait iki fonksiyon ve ağırlıkların değiştirilmesinde kullanılan öğrenme algoritmaları (learning algorithms) önemli rol oynar. Neuronun bilgi işleme faaliyetini yerine getirmesi biri toplam fonksiyonu diğeri geçiş fonksiyonu olmak üzere iki fonksiyon tarafından gerçekleştirilir (Şekil 4.4).

¹⁷ TRIPPI-TURBAN, A.g.e., pp.7-8.

Şekil 4. 4 :Toplam ve geçiş fonksiyonu



4.2.2.1. Toplam Fonksiyonu

Toplam fonksiyonunun neurona gelen tüm girdilerin ağırlıklı toplamını almak şeklinde basitçe ifade edebileceğimiz bir görevi bulunmaktadır. Bu amaçla hücreye ait (j) adet girdinin değeri (x_i) ile bu girdilerin ağırlık değerleri (w_{ki}) çarpılarak, toplamı (a_j) alınır.

$$\sum_{i=1}^n x_i \cdot w_{ki} = a_j$$

Bu toplam neurona gelen toplam ağırlıklı uyarıyı oluşturur. Bu toplam değer daha sonra geçiş fonksiyonu tarafından işlenecektir. Toplam fonksiyonunun Max, Min, And ve Or gibi değişik şekilleri de bulunmaktadır.¹⁸

¹⁸ www.dacs.dtic.mil/techs/neural/neural_ToC.html, 15.10.1998

4.2.2.2. Geçiş Fonksiyonu

Toplam fonksiyonu bir neuron'un ne düzeyde uyarılacağını belirleyen bir fonksiyondur.¹⁹ Bir neuron'un hangi uyarılma düzeyinden sonra çıktı (y_i) üreteceği ve çıktının uyarılma düzeyi ile ilişkisi ise, geçiş fonksiyonu tarafından belirlenmektedir.

$$f(a_j)=y_j$$

Bu ilişki çıktının hangi aralıklarda olacağını belirlemesi açısından da önemlidir.²⁰ Çünkü toplam fonksiyonu tarafından üretilen değer oldukça büyük olabilir ve değer çıktı için kullanıldığında, birkaç katman sonra çıktı değeri çok büyük değerlere ulaşacağı için çıktının 0, 1 veya bazen -1, +1 aralığına dönüştürülmesi gerekmektedir.²¹

Geçiş fonksiyonu olarak sıklıkla kullanılan fonksiyonlar (Şekil 4.5):

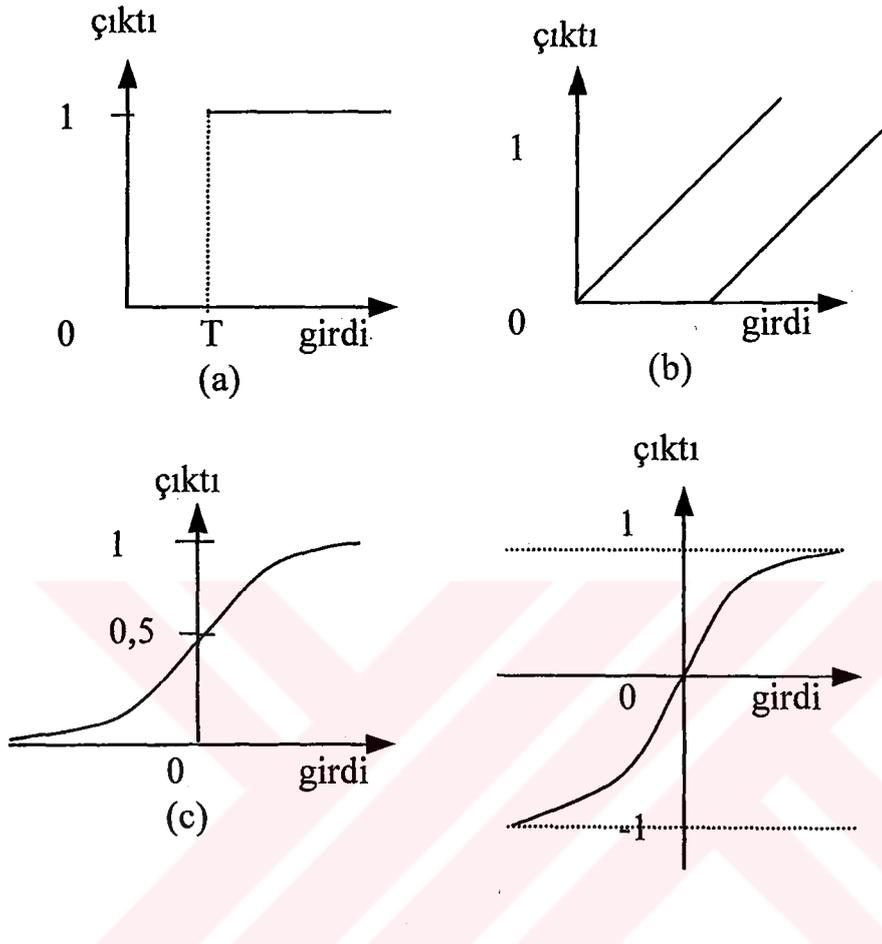
- i. İkili (binary) veya eşik fonksiyonu,
- ii. Doğrusal fonksiyon,
- iii. Sigmoid fonksiyon,
- iv. Hiperbolik Tanjant Fonksiyonu'dur.

¹⁹ VEMURI, A.g.e., p.43.

²⁰ A.g.e.

²¹ TRIPPI-TURBAN, A.g.e., pp.8-9.

Şekil 4. 5 : Değişik geçiş fonksiyonları



İkili adım fonksiyonunda çıktı değerinin (y) oluşması için girdi değerinin belli bir (T) değerine ulaşması gerekmektedir. (T) değerinden önce çıktı "0" iken, bu değerden sonra çıktı "1" değerini alır (Şekil 4.5-a).

Doğrusal geçiş fonksiyonunda çıktı=girdi olurken, adımlı doğrusal geçiş fonksiyonunda T eşik değeri aşıldıktan sonra $y = girdi - T$ şeklinde olmaktadır (Şekil 4.5-b).

Geçiş fonksiyonları içinde belki de en çok kullanılanı sigmoid fonksiyondur. Sigmoid fonksiyon girdinin tüm değerleri için 0-1 arasında bir değer üretmesi en önemli özelliğidir (Şekil 4.5-c).

Burada :

$$y_j = \frac{1}{1+e^{-y}} \quad \text{veya} \quad y_j = \frac{1}{1+e^{-y.c}} \text{ 'dir}$$

Bu formülde c öğrenme oranı olarak bilinen ve değeri sistem tasarımcısı tarafından belirlenen bir katsayı olup sigmoid fonksiyonun "0" noktasına olan eğimini belirler. Söz konusu c değeri yükseldikçe sigmoid fonksiyon orjine keskin adımlarla yaklaşır.²²

Sigmoid fonksiyonun biraz farklı şekli hiperbolik tanjant fonksiyonudur. Sigmoid fonksiyondan farklı, fonksiyonun çıktılarının -1 ve +1 arasında değerler almasıdır(Şekil 4.5-d).

$$y_j = \frac{e^u - e^{-u}}{e^u + e^{-u}}$$

Burda $u = y_j.c$ 'dir.

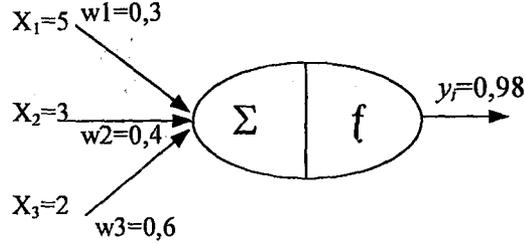
Geçiş fonksiyonu çıktı olarak sadece 0-1 den oluşan ikili değerler alabileceği gibi 0 ile 1 veya -1 ile +1 arasında sürekli değer de alabilir. Ayrıca sistemin parametrelerinden olan eşik değerinin (T) ve c 'nin (kazanç katsayısı olarak da bilinmektedir) ne olacağı ağı tasarlayan tasarımcıya bağlıdır.²³

Aşağıda bir neuronun işleyişi örnek olarak verilmiştir(Şekil 4.6):

²² ROJAS Raul, *Neural Networks: A Systematic Introduction*, Springer-Verlag, Berlin, 1996, pp.150.

²³ ZAHEDI, A.g.e., p.524.

Şekil 4. 6 :Bir neuronun işleyişine örnek



Toplam fonksiyonu gereği $\Sigma = 5.0,3 + 3.0,4 + 2.0,6 = 3,9$

Geçiş fonksiyonu olarak sigmoid fonksiyon kullanıldığında:

$$y_i = f(3,9) = \frac{1}{1 + e^{-3,9}} \cong 0,98$$

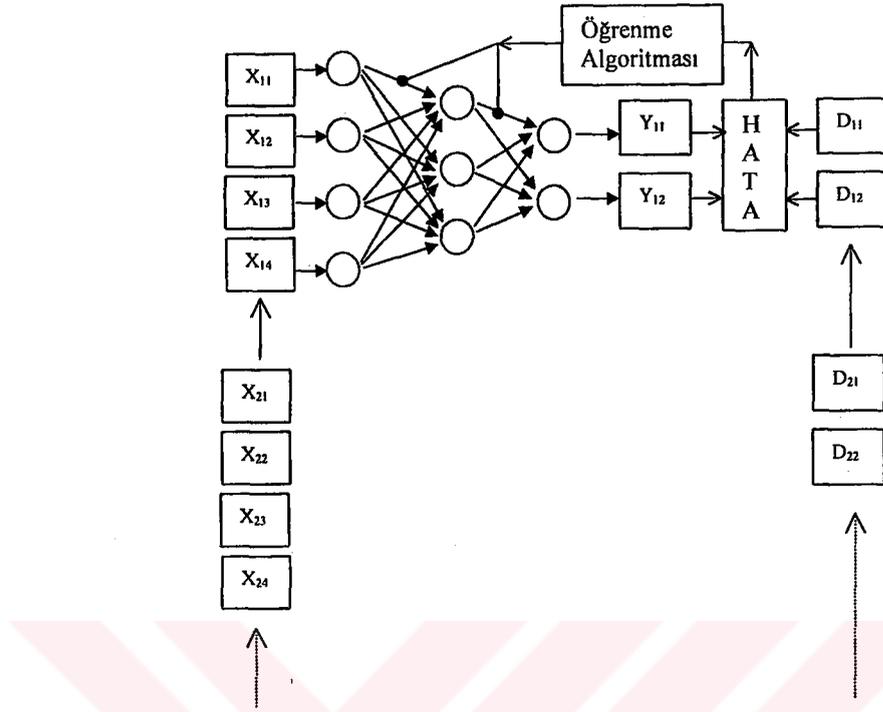
olmaktadır.

4.2.2.3.Yapay Sinir Ağında Öğrenme ve Öğrenme Algoritmaları

Basitçe ifade etmek gerekirse bir yapay sinir ağı "hata yaparak" öğrenir. Yapay sinir ağının öğrenme sürecinde temel olarak üç adım bulunmaktadır (Şekil 4.7).

- i. Çıktıları hesaplamak,
- ii. Çıktıları hedef çıktılarla karşılaştırmak ve hatayı hesaplanmak,
- iii. Ağırlıkları değiştirerek süreci tekrarlamak.

Şekil 4. 7 : Öğrenme süreci ve öğrenme algoritması



x_{ij} =girdiler y_{ij} =çıktılar O_{ij} = hedef çıktılar

Yapay sinir ağı öğrenme sürecinde, gerçek hayattaki problem alanına ilişkin veri ve sonuçlardan, bir başka deyişle örneklerden yararlanır. Gerçek hayattaki problem alanına ilişkin değişkenler yapay sinir ağının girdi dizisini, bu değişkenlerle elde edilmiş gerçek hayata ilişkin sonuçlar ise yapay sinir ağının ulaşması gereken hedef çıktılar dizisini oluşturur. Bu eğitim setindeki girdi ile çıktı arasındaki ilişkiyi belirleyen örüntü, yapay sinir ağının öğrenmesi istenen örüntüdür ve yapay sinir ağının ağırlık değerleri bu örüntüyü yansıtır. Yapay sinir ağının eğitilebilmesi için çok sayıda girdi ve girdilere ilişkin çıktı dizisine gereksinim duyulur. Yapay sinir ağının eğitilmesinde kullanılan girdi ve çıktı dizileri çiftinden oluşan verilerin tümüne "eğitim seti" adı verilir.²⁴

²⁴ VEMURI, A.g.e.,p.51.

Yapay sinir ağının öğrenme sürecinde yapılan temel iş, ağırlık değerlerinin değiştirilmesidir.²⁵ Amaç tüm girdi dizileri için çıktı dizisinin doğrulukla üretilbileceği şekilde yapay sinir ağının ağırlıklarının düzenlenmesidir.²⁶ Bunu neurona gelen girdilerin katsayılarının düzenlenmesi olarak görmek mümkündür. Böylelikle yapay sinir ağı, kullanılan girdi ve çıktılara bağlı olarak, gerçek hayattaki örüntüyü temsil eder duruma gelmektedir.

Öğrenme sürecinde yapay sinir ağının istenen çıktıları üretecek şekilde ağ içindeki ağırlıkların düzenlenmesini sağlayan mekanizma "öğrenme algoritması" (learning algorithm) veya "öğrenme kuralı" (learning rule) olarak adlandırılır (Şekil 4.7).²⁷

Öğrenme sürecinin başlangıcında yapay sinir ağının ağırlıkları rastgele atanmış durumdadır. Girdiler, girdi katmanından başlayarak gizli katmanlara ve çıktı katmanına işlenerek geçirilir. Böylelikle yapay sinir ağı, ağırlıklar ile toplam ve geçiş fonksiyonlarının etkisi altında bir çıktı dizisi üretmiş olur. Bu çıktılar ile hedef çıktılar arasında hesaplanan fark "hata" olarak adlandırılır. Bu hata, yapay sinir ağının ağırlıkları ile istenen çıktılar arasındaki farkın giderilmesi için ağ içinde kullanılmaktadır (Şekil 4.8).²⁸

Eğitim sırasında yapay sinir ağının ağırlıklarının derece, derece değiştirilmesi ve yapay sinir ağının istenen çıktıları üretecek şekilde uygun ağırlıkların bulunması süreci, çok sayıda tekrarlanan döngüler gerektirir.²⁹ Eğitim setinin bu döngü içinde yapay sinir ağından bir defa

²⁵ RUMELHART D.E.-HINTON G.E.-McCLELLAND, "A General Framework for Parallel Distributed Processing", *Parallel Distributed Processing: Explorations in the Microstructure of Cognition*, Vol: 1, MIT Press Cambridge, Massachusetts, 1986, p.51.

²⁶ VEMURU, A.g.e., p.51.

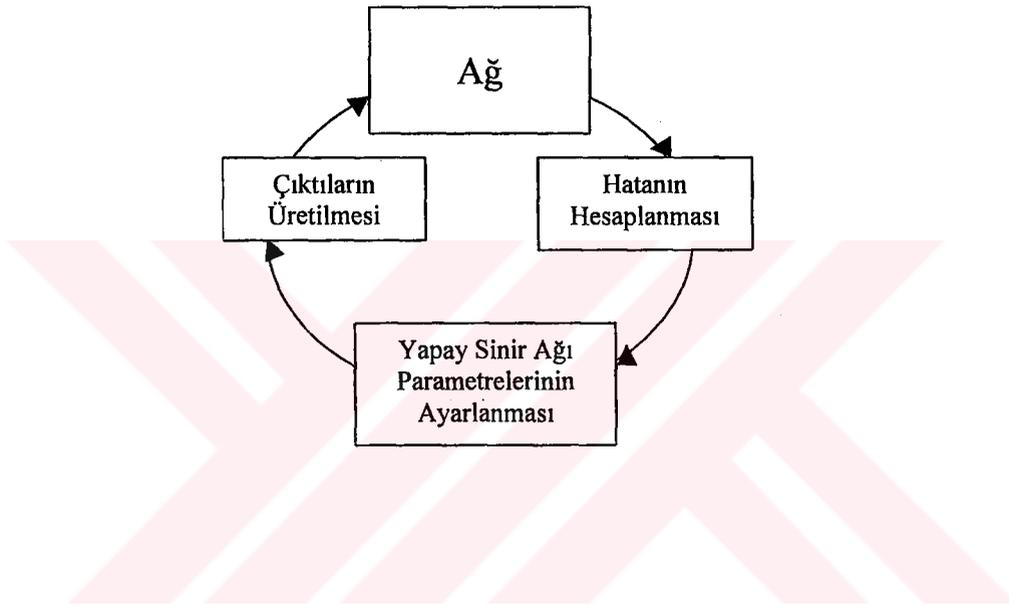
²⁷ ROJAS, A.g.e, p.77.

²⁸ BAŞBUĞ Ragıp, "Yapay Sinir Ağları", *Byte*, (Şubat 1994), s.167.

²⁹ ROJAS, A.g.e., p.77.

geçmesi devir (epoch) olarak adlandırılır.³⁰ Bir yapay sinir ağının öğrenme sürecinin tamamlanması için gerekli devir sayısı oldukça değişkendir. Tanınması gereken örüntü karmaşıklıkla birlikte gerekli devir sayısı artar, ancak kullanılan yapay sinir ağı mimarisi ve öğrenme algoritması da devir sayısını belirleyen önemli bir etkidir.

Şekil 4. 8 : Öğrenme sürecinde hatanın hesaplanması



Kaynak: ROJAS Raul, *Neural Networks: A Systematic Introduction*, Springer-Verlag, Berlin, 1996, p.77'den değiştirilerek alınmıştır.

Yapay sinir ağlarında, kullanılan öğrenme algoritmaları üç grupta incelenmektedir.³¹

- i. Öğreticili öğrenme (Supervised Learning): Öğreticili öğrenmede bir dış öğreticinin ağı her bir girdi için ağın üretmesi beklenen "doğru" sonuçları hedef çıktı olarak verdiği düşünülür. Bu öğrenmede ağın ürettiği çıktılar ile

³⁰ BAŞBUĞ, A.g.e., s.167.

³¹ HINTON Geoffrey E., "Connectionist Learning Procedures", *Artificial Intelligence*, V:40, N:1, p.189.

hedef çıktılar arasındaki fark hata olarak ele alınır ve bu hata minimize edilmeye çalışılır.³²

- ii. Öğreticisiz Öğrenme (Unsupervised Learning): Bu tür öğrenmede ağa sadece girdiler verilir. Ağın ulaşması gereken hedef çıktılar bulunmaz. Ağ bu girdiler arasındaki ilişkiyi bir başka ifadeyle girdi setindeki örüntüyü öğrenmeye çalışır. Böylelikle ağ kendini girdi setindeki örüntüye uyumlaştırır.³³
- iii. Takviyeli öğrenme (reinforcement training) yöntemi öğreticili öğrenme yöntemine benzemekle birlikte, ağa hedef çıktılar yerine, ağın çıktılarının ne ölçüde doğru olduğunu belirten bir skor veya derece bildirilir.³⁴

Kullanılan çok sayıda öğrenme algoritması bulunmaktadır. Yapay sinir ağının mimarisine, karşılaşılan sorunun niteliğine göre farklılık gösteren bu öğrenme algoritmalarının yüzden fazla çeşidi bulunmakla beraber en çok kullanılan öğrenme algoritmaları:

- i. Hebb,
- ii. Delta,
- iii. Geri Yayılma (Genelleştirilmiş Delta),
- iv. Kohonen,
- v. Hopfield,

³² HERTZ John- KROGH Anders - PALMER Richard G., **Introduction To The Theory of Neural Computation**, Addison-Wesley Publishing Company ,Redwood City (CA), 1991, p.10

³³ **A.g.e.**

³⁴ HECHT-NEILSEN Robert, **Neurocomputing**, Addison-Wesley Pub. Comp., ,Massachusetts, 1989, pp.48-49.

vi. Enerji fonksiyon.

Bu öğrenme algoritmaları içinde ilk ortaya çıkmasından dolayı Hebb algoritması, Delta ve çok yaygın olarak kullanılan Geri yayılım algoritması (Backpropagation) aşağıda açıklanmıştır.³⁵

i. Hebb Algoritması

1949 yılında kanadalı psikolog Donald Hebb tarafından biyolojik temele dayalı olarak geliştirilmiş olan Hebb algoritması en eski ve en ünlü öğrenme algoritmasıdır. Bu öğrenme algoritması basit bir mantığa dayanmaktadır: Eğer neuron (A) başka bir neuron' dan (B) girdi alıyorsa ve her ikisi de aktifse, (A) ve (B) arasındaki ağırlık artar.³⁶ Bu düşüncenin en çok kullanılan şekli:

$$\Delta w_{jk} = \alpha \cdot y_j \cdot x_k$$

Burada $\Delta w_{jk} = \Delta w_{jk}^{(t)} = w_{jk}^{(t+1)} - w_{jk}^{(t)}$ ve $\alpha > 0$ dır (t=zaman).

Bu formülde w_{jk} neuron u_k ' den neuron u_j ' ya olan ağırlık, y_j neuron u_j ' nin çıktısı ve x_k ise u_k neuronun çıktısıdır. α "öğrenme oranı" veya " öğrenme katsayısı" olarak adlandırılmaktadır ve birçok öğrenme algoritması tarafından kullanılır. Öğrenme katsayısı "0" ile "1" arasında bir değer alır ve bu değer ağırlık öğrenme hızını belirler. α 'nın büyük değerleri

³⁵ Ayrıca Bkz.: HECHT-NEILSEN, A.g.e., pp.46-77.; VEMURI, A.g.e., p p.53-56.; GALLANT, A.g.e., p p.61-251.

³⁶ HAYKIN Simon, *Neural Networks : A Comprehensive Foundation*, Prentice Hall Int., Inc., New Jersey, 1994, p.49.

için daha hızlı öğrenme, küçük değerleri için daha yavaş öğrenme gerçekleşmektedir. Ancak hızlı öğrenme ağı "genelleme" yeteneğini azaltır ve genelleme yeteneği ağı eksik ve gürültülü verilerle doğru sonuçlar üretebilmesi için oldukça önemlidir.³⁷ Hebb algoritmasıyla ilgili bir diğer konuda ağı eğitmeden önce ağırlıklarının 0 olması gerektiğidir.³⁸

ii. Delta Algoritması

Delta algoritması ilk olarak Widrow ve Hoff tarafından geliştirilmiş daha çok mühendislik kökenli bir algoritmadır. Bu algoritma en küçük kareler kuralı olarak da bilinmektedir (Least-Mean-Square Rule LMS).³⁹

Delta algoritması bir neuronun çıktısının y_j , hedeflenen çıktı d_j 'den farkını "hata" olarak ele alınmaktadır ve neuron j için herhangi bir andaki hata δ_j şöyle hesaplanır:⁴⁰

$$\delta_j = d_j - y_j.$$

Bu algoritma, hata karelerinin ortalamasını alarak, bu değerin en küçük olduğu çözümü bulmaya amaçlar. Ağ için hata karelerinin ortalaması ξ , aşağıdaki gibi hesaplanır:⁴¹

$$\xi = E \left[\frac{1}{2} \sum_j \delta^2 \right]$$

³⁷ ZAHEDI, A.g.e. p.527; WASSERMAN D. Philip-SCHWARTZ Tom , "Neural Networks, Part 2", **IEEE Expert**, Spring 1988, p.10.

³⁸ ROJAS, A.g.e., p.315.

³⁹ WIDROW Bernard, LEHR Michael A., "30 Years of Adaptive Neural Networks: Perceptron, Madaline, and Backpropagation", **Proceedings of the IEEE**, V:78, N:9 (September 1990), pp.1417.

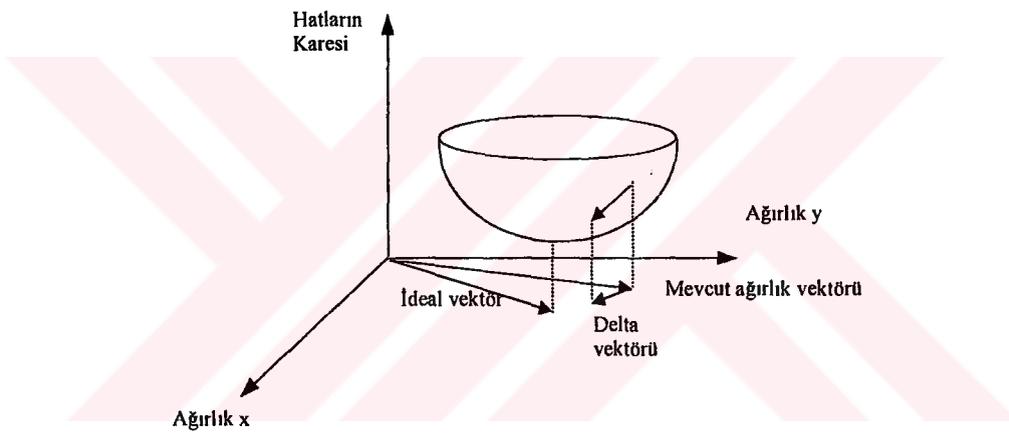
⁴⁰ HAYKIN, A.g.e., p.47.

⁴¹ A.g.e.

Burada E istatistiksel olarak beklenen değeri (ortalamayı) ifade etmektedir.

Delta algoritması hataların karesinin en küçük olduğu noktayı bulurken dereceli azaltma yöntemini (gradient descent) kullanmaktadır. Bu yöntemde, hata kareleri, koordinatlarını ağırlıkların oluşturduğu uzayda bir çanak oluşturmaktadır (Şekil 4.9). Delta algoritması mevcut ağırlık vektörünü bulunduğu konumdan hatanın en küçük olduğu çanağın dibine doğru ilerletir.⁴²

Şekil 4. 9 : Delta algoritmasında ağırlık değişimi



Kaynak: CAUDILL Maureen, "Neural Networks Primer, AI Expert, (June,1988), pp.53-59.

İşlem elemanının doğrusal geçiş fonksiyonuna sahip olduğu kabul edildiğinde;

$$y_j = \sum_k w_{jk} x_k$$

Hata karelerinin ortalamasının en küçük olduğu noktayı bulmak için ağırlıklar t=zaman olmak üzere t=1,2,3,... için aşağıdaki gibi değiştirilir:⁴³

⁴² CAUDILL Maureen, "Neural Networks Primer Part III, AI Expert, (June,1988), pp.53-59.

⁴³ VEMURİ, A.g.e., p.52.

$$w_{ij}^{(t+1)} = w_{ij}^{(t)} + \Delta w_{ij}$$

$$\Delta w_{ij} = \alpha \cdot \delta_j^{(t)} \cdot x_k^{(t)}$$

iii. Geriyayılım Algoritması

Geriyayılma algoritması veya bir başka adıyla Genelleştirilmiş Delta Algoritması belki de en çok kullanılan öğrenme algoritmasıdır. Hata ağdaki ağırlıkların bir fonksiyonu olarak görülür ve hataların kareleri ortalaması delta algoritmasında olduğu gibi dereceli azaltma (gradient descent) yöntemi kullanılarak, minimize edilmeye çalışılır.⁴⁴

Aslında, geriyayılım algoritması, delta algoritmasının bir momentum terimi eklenmiş halidir. Momentum terimi hatalarının en küçük olduğu noktayı bulmada, doğrultunun ayarlanmasına yardımcı olur. Ayrıca delta algoritmasında olduğu gibi, ağırlıkların bazı yerel çukurlarda takılarak yanlış çözüme ulaşmasını momentum terimi tarafından önlenir. Ancak bu hiçbir zaman büyük bir engelin doğru sonuca ulaşmasını engelleyemeyeceği anlamına gelmemelidir.⁴⁵

Geriyayılım algoritmasının birkaç değişik varyasyonu olmakla birlikte en yaygın hali delta algoritmasına bir momentum teriminin eklenmiş halidir:

$$\Delta w_{ij}^{(t)} = \alpha \cdot \delta_j^{(t-1)} \cdot x_k^{(t-1)} + \mu \Delta w_{ij}^{(t-1)}$$

⁴⁴ A.g.e., p.53.

⁴⁵ CAUDILL, A.g.e., p.58.

4.3.YAPAY SİNİR AĞI MİMARİLERİ

Yapay sinir ağlarında, neuronlar arası bağlantı farklılıklarından kaynaklanan, değişik yapay sinir ağı mimarileri bulunmaktadır. Bu mimariler arasında performans ve karakteristik özellikleri bakımın farklar bulunmaktadır. Mimari farklılıklar özellikle ağın modelleme yeteneğini belirledikleri için oldukça önemlidirler. Yapay sinir ağının tasarımı aşamasında bu mimariler arasından uygulamaya en elverişli olanı seçilir. Mimarilerin hangi alanlarda uygulanmaya daha elverişli oldukları yapay sinir ağının geliştirilmesi konusunda işlenecek olduğundan burada tekrara yer verilmeyerek sadece mimariler tanıtılacaktır.

4.3.1. İleri Beslemeli Ağlar

İleri beslemeli ağlarda, işlem elemanları birbiri ardı sıra sıralanırlar. Girdiler dışarıdan ya da bir önceki neurondan alınır; neuronların çıktıları da bir sonraki neurona veya dışarıya verilir (Şekil 4.10 a). Bu ağlarda, neuronun önceki veya aynı katmandaki herhangi bir neurona bağlantısı ve veri iletmesi söz konusu değildir. Bu mimarilerde ağın çıktısı, tamamen ağa giren girdilere bağlıdır. İleri beslemeli ağlar herhangi bir dinamiklik özelliği taşımazlar ve gösterdikleri özellik bakımından doğrusal ve doğrusal olmayan kararlı problem alanlarına uygulanabilirler.⁴⁶

4.3.2. Geri Beslemeli Ağlar

Geri beslemeli ağlarda işlem elemanlarının çıktıları daha gerilerdeki işlem elemanlarına girdi olarak kabul edilir (Şekil 4.10 b) . Geri beslemeli ağları ileri beslemeli

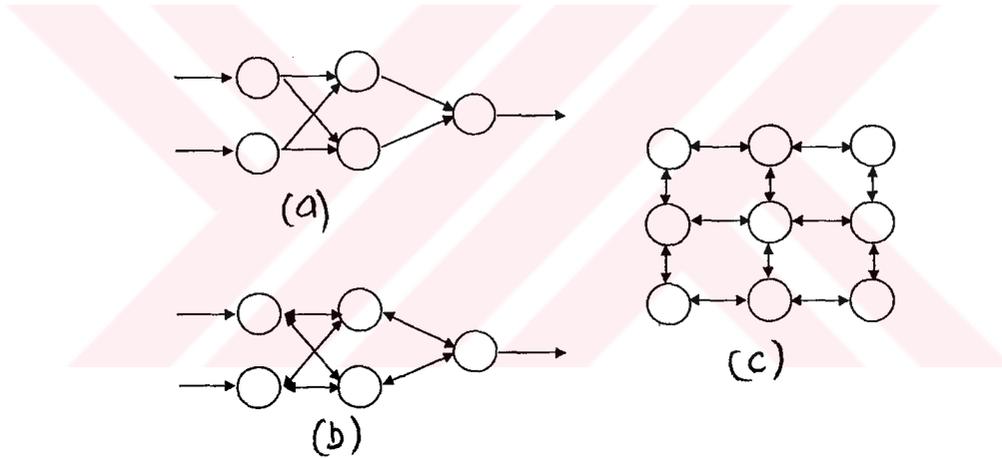
⁴⁶ CICHOCKI-UNBEHAVEN, A.g.e., p.64-65.

ağlardan ayıran temel özellik, bu tip mimariyle oluşturulan ağlar dinamik doğrusal olmayan sistemleri, özellikle doğrusal olmayan diferansiyel denklemleri modelleyebilmeleridir.⁴⁷

4.3.3. Hücresel Bağlantılı Ağlar

Hücresel bağlantılı ağlarda ise, bir işlem birimi sadece komşu bir işlem birimiyle bağlantılıdır. Bu tip mimaride bir hücre, komşusu olmayan hücrelerle ancak dolaylı ilişki içinde olabilmektedir. Hücreler arası bağlantı karşılıklı (iki yönlü) olmasından dolayı bir işlem elemanı kendi çıktısından da uyarılabilmektedir(Şekil 4.10 c).

Şekil 4. 10 : Temel yapay sinir mimarileri



4.4.YAPAY SİNİR AĞI GELİŞTİRME VE EĞİTME

Geleneksel bilgisayar uygulamalarının geliştirilmesinde karşılaşılan durum, bilgisayarın belli bilgisayar dilleri aracılığıyla ve kesin yazım algoritmalarına uygun ifadelerle programlanmasıdır. Bu oldukça zaman alan, uyumluluk konusunda zayıf, teknik personel gerektiren, çoğu zaman pahalı olan bir süreçtir. Oysa biyolojik temele dayalı yapay zeka

⁴⁷ A.g.e., p.65-66.

teknolojilerinden biri olan yapay sinir ağlarının geliştirilmesinde programlama, yerini büyük ölçüde "eğitime" bırakmaktadır.⁴⁸

Yapay sinir ağının geliştirilmesi sürecinde her biri bir aşama olan, ağın yapısına ve işleyişine ilişkin şu kararların verilmesi gerekir:⁴⁹

- i. Ağ mimarisinin seçilmesi ve yapı özelliklerinin belirlenmesi (katman sayısı, katmandaki neuron sayısı gibi),
- ii. Neurondaki fonksiyonların karakteristik özelliklerinin belirlenmesi,
- iii. Öğrenme algoritmasının seçilmesi ve parametrelerinin belirlenmesi,
- iv. Eğitim ve test verisinin oluşturulması.

4.4.1. Yapay Sinir Ağının Geliştirilmesi Aşamaları

4.4.1.1. Mimarinin Seçilmesi

Yapay sinir ağı geliştirilmesi sürecinde mimarinin seçilmesi büyük ölçüde ağda kullanılması düşünülen öğrenme algoritmasına bağlıdır. Ağda kullanılacak öğrenme algoritması seçildiğinde bu algoritmanın gerektirdiği mimaride zorunlu olarak seçilmiş olacaktır.⁵⁰ Örneğin geriyayılım algoritması ileri beslemeli ağ mimarisi gerektirir.

Yapay sinir ağının mimarisine ilişkin belirlenmesi gereken özelliklerden biri de sinir

⁴⁸ SCHALKOF, A.g.e., p.11.

⁴⁹ SCHALKOF Robert J., *Pattern Recognition: Statical, Structural and Neural Approaches*, John Wiley & Sons, inc., New York, 1992, p222-223.'den değiştirilerek alınmıştır.

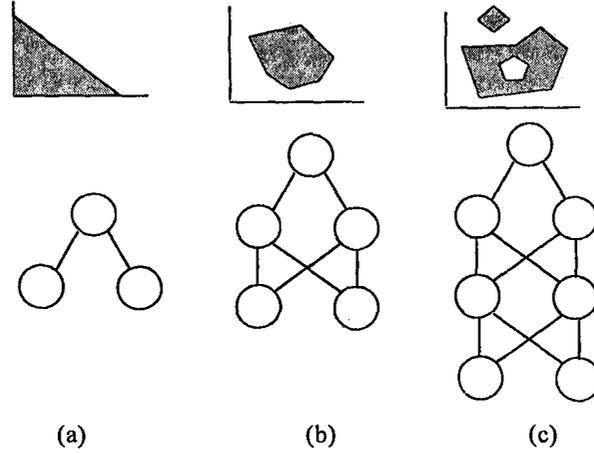
⁵⁰ HAYKIN. A.g.e., p.18.

ağında bulunacak katman sayısıdır. Yapay sinir ağında bulunan katman sayısı ile yapay sinir ağının gösterdiği istatistiksel özellikler arasında önemli bir bağlantı bulunmaktadır.

Yapay sinir ağları, özellikle bir girdinin A veya B gibi herhangi bir sınıfa ait olup olmadığı araştırıldığında bu istatistiksel özelliklerini sergileyebilmektedirler. Yapay sinir ağı eşik değerine sahip ve tek katmanlı bir yapı oluşturduğunda, doğrusal olarak ayrılabilen iki sınıflı örnekleme sınıflandırmak için kullanılabilir (Şekil 4.11.a). İki katmandan oluşan bir ağ ise her bir katman girdi uzayını bir düzlemle böldüğünden, bir çok düzlemin oluşturduğu dışbükey açık veya dışbükey kapalı bir girdi uzayını bölümleyebilir (Şekil 4.11.b). Üç katmanlı bir ağ girdi uzayını dışbükey olmayan ve parçalı bir biçimde bölümleyebilme yeteneği taşır (Şekil 4.11.c).⁵¹

⁵¹ BISHOP Christopher M., *Neural Networks for Pattern Recognition*, Clarendon Press, Oxford, 1997, pp.122-124.

Şekil 4. 11 : Ağdaki katman sayısı ve ağın sınıflandırma yeteneği



Kaynak : BISHOP Christopher M., *Neural Networks for Pattern Recognition*, Clarendon Press, Oxford, 1997, p.123..

Yapay sinir ağının tasarımı aşamasında, tasarımcı sorun alanına ilişkin girdi-çıkış ilişkisinin göstermiş olduğu istatistiksel özelliğe bağlı olarak ağdaki katman sayısına karar verecektir. Ancak çoğu problem alanı için 2 veya 3 katmanlı bir ağ tatmin edici sonuçlar üretebilmektedir.

Ağın yapısal özelliklerinden biri de her bir katmandaki neuron sayısıdır. Katmandaki neuron sayısının tespitinde genellikle deneme-yanılma yöntemi kullanılır. Bunun için izlenecek yol, başlangıçtaki neuron sayısını istenilen performansa ulaşınca kadar arttırmak veya tersi şekilde istenen performansın altına inmeden azaltmaktır.⁵² Bir katmanda kullanılacak neuron sayısı olabildiğince az olmalıdır. Neuron sayısının az olması yapay sinir

⁵² HECHT-NIELSEN, A.g.e., p.115.

ağının "genelleme" yeteneğini artırırken, gereğinden fazla olması ağın verileri ezberlemesine neden olur. Ancak gereğinden az neuron kullanılmasının verilerdeki örüntünün ağ tarafından öğrenilememesi gibi bir sorun yaratabilir.⁵³

4.4.1.2. Neuronun Karakteristik Özellikleri

Neuronun geçiş fonksiyonunun seçimi büyük ölçüde yapay sinir ağının verilerine ve ağın neyi öğrenmesinin istendiğine bağlıdır. Geçiş fonksiyonları içinde en çok kullanılan simoid ve hiperbolik tanjant fonksiyonlarıdır. Daha önce belirtildiği gibi sigmoid fonksiyonun çıktı aralığı 0 ve 1 arasında olurken, hiperbolik tanjant fonksiyonunun çıktısı -1 ve 1 aralığında oluşmaktadır. Eğer ağın bir modelin ortalama davranışını öğrenmesi isteniyorsa sigmoid fonksiyon, eğer ortalamadan sapmanın öğrenilmesi isteniyorsa hiperbolik tanjant fonksiyon kullanılması önerilmektedir.⁵⁴

4.4.1.3. Öğrenme Algoritmasının Seçimi

Yapay sinir ağının geliştirilmesinde kullanılacak çok sayıda öğrenme algoritması bulunmaktadır. Bunlar içinde bazı algoritmaların bazı tip uygulamalar için daha uygun olduğu bilinmektedir. Bu algoritmalar eğer uygun oldukları uygulama alanlarına göre sınıflandırılacak olursa, gruplar ve içinde yer alacak öğrenme algoritmaları aşağıdaki gibi özetlenebilir.

⁵³ TURBAN-TRIPPI, A.g.e., p.64.

⁵⁴ A.g.e., p.61.

Tablo 4. 1 : Öğrenme algoritmaları ve uygulandıkları alanlar

| Uygulama Tipi | Yapay Sinir Ağı |
|---|--|
| Öngörü Tanıma | <ul style="list-style-type: none"> • Geriyayılım • Delta Bar Delta • Geliştirilmiş Delta Bar Delta • Yönlendirilmiş Rastsal Tarama • Geriyayılım içinde Self Organizing Map • Higher Order Neural Networks |
| Sınıflandırma | <ul style="list-style-type: none"> • Learning Vektor Quantization • Counter-Propagation • Olasılıklı Yapay Sinir Ağları |
| Veri İlişkilendirme (Data Association) | <ul style="list-style-type: none"> • Hopfield • Boltmann Makinesi • Bidirectional Associative Memory • Spation -temporal Pattern Recognition |
| Veri Kavramlaştırma (Data Conceptualization) | <ul style="list-style-type: none"> • Adaptive Resonance Network • Self Organizing |

Kaynak : <http://dacs.dtic.mil/tech/neural/neural6.html>

Yapay sinir ağları belki de en çok öngörü amacıyla kullanılmaktadır. Öngörü için kullanılan yapay sinir ağları içinde de en yaygın olarak kullanılan geriyayılım algoritmasıdır.⁵⁵ Geriyayılım algoritması ileri beslemeli ve çok katmanlı bir ağ mimarisini gerektirmektedir.

Bu bölümün devamında, öğrenme algoritmalarına ilişkin parametrelerin

⁵⁵ <http://dacs.dtic.mil/tech/neural/neural6.html>

incelenmesinde geriyayılım algoritması temel alınarak konu incelenecektir. Ancak seçilen öğrenme algoritmasına göre parametreler ve parametre değerlerinin farklılık göstereceği unutulmamalıdır.

Öğrenme algoritması olarak geriyayılım algoritması seçildiğinde iki parametre önem kazanmaktadır. Bunlar öğrenme oranı (learning rate) ve momentum terimidir.

Öğrenme oranı, ağırlıkların bir sonraki düzeltmede hangi oranda değiştirileceğini göstermektedir. Bu oran asıl itibariyle ξ ile w_{ij} 'lerin oluşturduğu hata yüzeyine bağlıdır (Şekil 3.9). Eğer hata yüzeyi çok engebeli ise ağırlıkların bölgesel bilgiler üzerinden yaptığı hesaplamalarla hata yüzeyinin dibine ulaşması zorlaşır. Bu durumda küçük öğrenme katsayısı tercih edilmelidir. Ancak bu durum ağırlıkların sonuca ulaşmasını yavaşlatır. Eğer hata yüzeyi daha pürüzsüz ise, daha yüksek öğrenme oranı ağırlıkların sonuca ulaşma hızını arttıracaktır. Bununla birlikte çok yüksek oranlar ağırlıkların hesaplamalarında büyük salınımlara neden olur ve ağırlıkların dip noktayı bulmasını engelleyebilir.⁵⁶

Momentum terimi ise ağırlıkların salınımları engellemeye ve ağırlıkların hata yüzeyindeki bölgesel minimum noktalardan kaçarak, daha dip noktalara ulaşmasına yardımcı olur.⁵⁷ Optimal öğrenme oranı ve momentum teriminin belirlenmesi büyük ölçüde deneysel ve sezgisel bir özellik taşır.⁵⁸ Ayrıca bu parametreler büyük ölçüde ilgilenilen sorun alanına bağlı olarak değişiklik gösterir.

⁵⁶ SCHALKOF, Pattern..., p.245.

⁵⁷ A.g.e., p.247-249.

⁵⁸ HAKIN, A.g.e., p.171.

4.4.1.4.Eğitim ve Test Verisinin Oluşturulması

Yapay sinir ağı geliştirme sürecinde veriler ikiye ayrılır; bir bölümü daha önce belirtildiği gibi ağın eğitilmesi için kullanılır ve eğitim seti adını alır, diğer bölümü ağın eğitim verileri dışındaki performansını ölçmede kullanılır ve test seti olarak adlandırılmaktadır.⁵⁹

Eğitim ve test setleriyle ilgili temel sorun yeterli eğitim ve test verisinin miktarının ne olduğudur. Sınırsız sayıda verinin bulunabildiği durumlarda, yapay sinir ağı mümkün olan en çok veriyle eğitilmelidir. Eğitim verisinin yeterli olup olmadığı konusunda emin olmanın yolu; eğitim verisinin miktarının artırılmasının, ağın performansında bir değişiklik yaratmadığı noktaya kadar, veri miktarının artırılmasıdır. Ancak bunun mümkün olmadığı durumlarda yapay sinir ağının eğitim ve test verileri üzerindeki performansının yakın olması da verilerin sayıca yeterli olduğuna ilişkin bir gösterge olarak kabul edilebilir.⁶⁰ Bununla birlikte eğitim setinin içermesi gereken veri miktarı değişik yapay sinir ağı modellerine göre ve özellikle problemin gösterdiği karmaşıklığa göre farklılık gösterebilmektedir.⁶¹

4.4.2. Yapay Sinir Ağının Eğitimi ve Testi

Eğitim süreci sonucunda yapay sinir ağında hesaplanan hatanın kabul edilebilir bir hata oranına inmesi beklenir. Ancak hata kareleri ortalamasının düşmesi her zaman için yapay sinir ağının genellemeye (generalization) ulaştığını göstermez. Yapay sinir ağının gerçek amacı girdi-çıkı örnekleri için genellemeye ulaşmaktır.

⁵⁹ ZAHEDI, A.g.e., p.604.

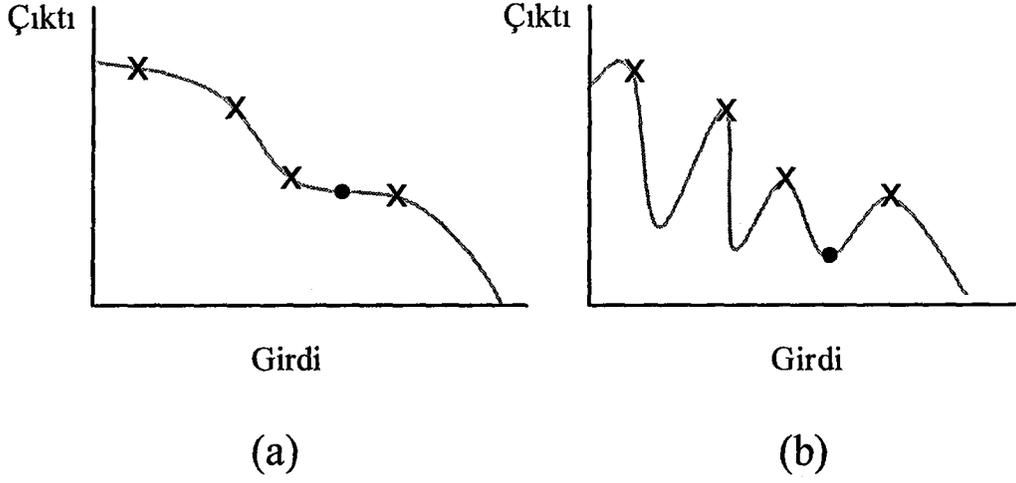
⁶⁰ HECHT-NEILSEN, A.g.e., p.115.

⁶¹ HAYKIN, A.g.e., p.179-179.

Genelleme, yapay sinir ağının eğitimde kullanılmamış ancak aynı evrenden gelen girdi-çıkı örneklerini ağın doğru bir şekilde sınıflandırabilme yeteneğidir. İstatistiksel açıdan genelleme bir uygun eğrinin bulunması (curve-fitting) veya doğrusal olmayan ara değer atama işi (interpolation) olarak görülebilir. Şekil 4.12 (a) 'da genellenenin nasıl gerçekleştiği görülmektedir. Şekilde (x) ile görülen noktalar eğitim verileridir. Bunların arasında kalan eğri ise ağ tarafından oluşturulmaktadır. Bu eğri üzerindeki farklı bir girdi değeri için (•) üretilen doğru çıktı değeri, ağın iyi bir genelleme yaptığını gösterir. Ancak ağ gereğinden fazla girdi-çıkı ilişkisini öğrendiğinde, ağ verileri "ezberlemektedir" (memorization). Bu durum genellikle gereğinden fazla gizli katman kullanıldığında verilerin synaptic bağlantılar üzerinde saklanması veya gereğinden fazla veri kullanılarak eğitilmesinden (overtraining) kaynaklanmaktadır. Ezberleme, genellenenin iyi gerçekleşmediğini ve girdi-çıkı eğrisinin düzgün olmadığını gösterir (Şekil 4.12 b).⁶² Verilerin ezberlenmiş olması yapay sinir ağı için istenmeyen bir durum olup, verileri ezberleyen ağa ait eğitim hatası oldukça düşme, test verilerinde ise hata artma eğilimi gösterir. Bundan dolayı bir çok yapay sinir ağı yazılımı ağın eğitim ve test verilerine ait hataları grafik olarak göstermektedir. Verileri ezberleyen ağ gerçek hayattaki örüntüyü iyi temsil edemeyeceği için kullanılamaz. Şekil 4.13 -a 'da ağ verileri ezberlediği için eğitim hatası azalma, test hatası ise artma eğilimi göstermektedir. Şekil 4.13-b 'de ise ağ kabul edilebilir bir genellemeye ulaşmıştır.

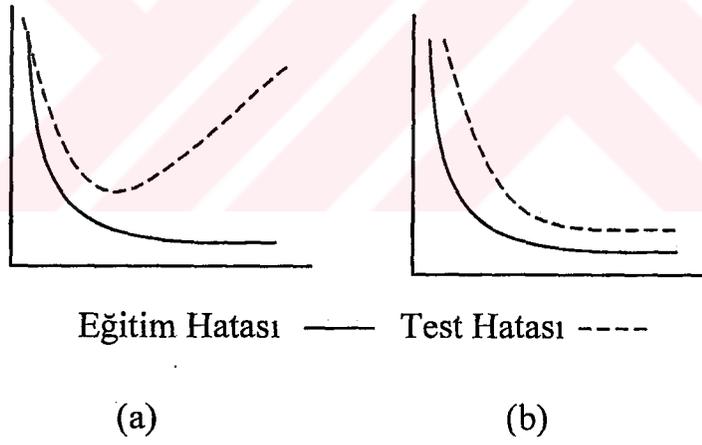
⁶² A.g.e., p.176-178.

Şekil 4. 12 : Genelleme ve ezberleme



Kaynak : HAYKIN Simon, **Neural Networks : A Comprehensive Foundation**, Prentice Hall Int., Inc., New Jersey, 1994, p.177.

Şekil 4. 13 : Verileri ezberleyen ve iyi genellemeye ulaşan ağlardaki hata eğrileri



4.5.YAPAY SİNİR AĞI TEKNOLOJİSİNİN DEĞERLENDİRİLMESİ

Yapay sinir ağı özellikle doğrusal olmayan sistemlerde öngörüler açısından istatistik tekniklere göre daha kolaylık sağlayan bir özelliğe sahiptir. Bundan dolayı başta işletmecilik

ve finans olmak üzere bir çok değişik alanlarda kullanım imkanı bulur.⁶³

Yapay sinir ağlarını diğer uygulamalardan ayıran avantajları şu şekilde sıralamak mümkündür:⁶⁴

- i. Genelleme : Yapay sinir ağının öğrenme yeteneğinin en büyük avantajı, genellemeye ulaşmış bir ağın eksik ve hatalı verilerle doğru sonuçlara ulaşabilmesidir. Örneğin yapay sinir ağlarının en ilginç kullanım alanlarından birisi de insan yüzlerini tanıma konusunda eğitilmiş ağın, karanlıkta, değişik açılardan çekilmiş fotoğraflarla kişileri doğru olarak tanımasıdır.
- ii. Hata toleransı : Geleneksel bilgisayar sistemleri, sistemde oluşacak hatalara karşı çok duyarlıdır. Sistemde meydana gelebilecek en ufak bir hata sonuca ulaşamama veya sonuçlarda büyük hataya yol açabilmektedir. Ancak yapay sinir ağının bir veya birkaç neuronun zarar görmesi sistemin geleneksel bilgi işlem teknolojilerinde olduğu kadar etkilemez.
- iii. Uyum Gösterme : Yapay sinir ağının gösterdiği önemli özelliklerden birisi ağın eğitim dışında, kullanım sürecinde de yeni ortamları da öğrenebilir ve uyum gösterebilir yetenekte olmasıdır.
- iv. Paralel çalışma : Sinir ağındaki tüm işlem elemanları paralel olarak çalıştıkları için uygulama sürecinde hızlı çözümler üretirler.

⁶³ GOONATILAKE Suran - TRELEAVEN Philip, *Intelligent Systems For Finance and Business*, Wiley Chichester, 1995, p.10.

⁶⁴ TRIPPI-TURBAN, A.g.e., pp:10-12.; SCAHALKOF, A.g.e., p.10; GOONATILAKE-TRELEAVEN, A.g.e., p 10.

- v. Herhangi bir varsayıma gerek duymaması : Yapay sinir ağı yazınında verilerin yapay sinir ağının eğitiminde kullanılması için gerekli bir varsayıma rastlanmamıştır. Bir başka deyişle her tür veri sayılarla kodlanması şartıyla eğitim için kullanılabilir. Bu yapay sinir ağı teknolojisinin sahip olduğu önemli bir avantajdır.

Yapay sinir ağının yukarıda sayılan avantajları dışında bazı uygulamalara uygun olmayan dezavantajları da bulunmaktadır. Bunlar:⁶⁵

- i. Uygun çözüme ulaşamama : Yapay sinir ağlarının her alana uygulanabilir ve her zaman çözüme yüzde yüz ulaşacak bir özellik taşıdığını düşünmek yanlış olacaktır. Bu teknoloji bazı sorun alanlarında eğitim verisine bağlı olarak, ilgisiz ve kabul edilemez sonuçlar üretebilmektedir. Bazı alanlarda ise ağın eğitimi mümkün olamamaktadır.
- ii. Açıklama eksikliği : İstatistiksel çözümler beraberinde sorun alanına ilişkin anlaşılabilir ve yorumlamaya olanak veren parametreler üretmesine rağmen, yapay sinir ağlarının synaptik ağırlıklarını henüz yorumlama imkanı bulunmamaktadır. Bu nedenle yapay sinir ağıyla ulaşılan sonuçlarda model kapalı bir kutu olarak kalmaktadır.

⁶⁵ TRIPPI-TURBAN, A.g.e., p.12.; SCAHALKOF, A.g.e., p.10; GOONATILAKE-TRELEAVEN, A.g.e., p 10.

4.6.YAPAY SİNİR AĞI KULLANIM ALANLARI

Yapay sinir ağları aşağıdaki özellikleri gösteren alanlarda kullanıma uygun bir araçtır.⁶⁶

- i. Çok değişkenli problem uzayı,
- ii. Probleme ilişkin değişkenler arasında karmaşık etkileşim,
- iii. Çözüm uzayının bulunmaması, tek bir çözümün olması veya çok sayıda çözüm bulunması.

Yapay sinir ağlarının çok geniş uygulama örnekleri bulunmaktadır. Yukarıdaki niteliklere uygun bazı uygulamalar olarak konuşma anlama, optik karakter tanıma, İngilizce teleffuz, radarda hedef tanıma ve sınıflandırma, tıbbi teşhis sayılabilir. Yapay sinir ağlarının muhasebe ve finans alanında ise çok sayıda ve bazıları ticarileşmiş uygulamalar bulunmaktadır.⁶⁷ Yapay sinir teknolojisi giderek daha fazla kullanım alanı bulmaktadır. Ayrıca yapay sinir ağı teknolojisinin, genetik algoritmalar, bulanık mantık ve uzman sistemlerle birlikte uygulanması umut verici gelişmeler olarak melez teknolojileri gündeme getirmektedir.⁶⁸

4.7.MUHASEBE BİLGİ SİSTEMİ VE YAPAY SİNİR AĞI TEKNOLOJİSİ İLİŞKİSİ

İşletmenin değişik düzeylerindeki yöneticiler karar verirken işletmedeki değişik bilgi sistemlerinden yararlanırlar. İşletme bilgi sistemini oluşturan bu bilgi sistemleri ve özellikleri

⁶⁶ SCHALKOF, Pattam..., p.206-207.

⁶⁷ HAWLEY D. Delvin-JOHNSON John D.- RAINA Dijjotam, "Artificial Neural Systems : A New Tool for Financial Decision-Making", *Financial Analysts Journal*, November-December, 1990, pp.63-72.

⁶⁸ WONG F.S.-P.Z. WANG- GOH T.H.-QUEK B.K., "Fuzzy Neural Systems for Stock Selection", *Financial Analysts Journal*, January-February 1992, pp.47-52.

aşağıdadır:⁶⁹

- i. Veri kayıt sistemi (transaction processing system) : Veri kayıt sistemi işletmede gerçekleşen olayların kayıt altına alınmasını ve güncellenmesini sağlayan bilgi sistemidir. Genellikle işletme çalışanları tarafından verilerin girilmesi ve güncellenmesi amacıyla kullanılır.
- ii. Yönetim bilgi sistemi (management information system) : Yönetim bilgi sistemi, veri kayıt sistemi tarafından oluşturulan çok sayıdaki ve çeşitteki verileri özetleyerek bilgi haline getirir ve yöneticilerin kullanabileceği raporlar haline dönüştürür. Ayrıca işletmede tekrar eden, programlanabilir, rutin kararların alınmasını otomasyon halde verilmesini sağlayan bilgi sistemidir. Bu bilgi sisteminden alt ve orta düzey yöneticiler yararlanır.
- iii. Karar destek sistemi (decision support system) : Yöneticilerin yapısal ve yarı yapısal nitelikteki kararların verilmesine yardımcı olmak için, çeşitli modelleme araçlarını ve hazır modelleri, bir veri tabanı eşliğinde yöneticilerin kullanımına sunan bilgi sistemidir. Bu bilgi sisteminden orta üst düzey yöneticiler karmaşık, stratejik ve her zaman karşılaşılmayan kararların verilmesinde yararlanırlar.

⁶⁹ Ayrıca Bkz: MURPHY C.-CURRIE J.-FAHY M. GOLDEN W., "DSS In Management Accounting", **Management Accounting (London)**, February 1995, pp.37- March 1995, pp.54.; MAWDUDUR Rahman-HALLADAY Maurice, **Accounting Information Systems**, Second Ed., Prentice Hall Inc., N.J.,1992.

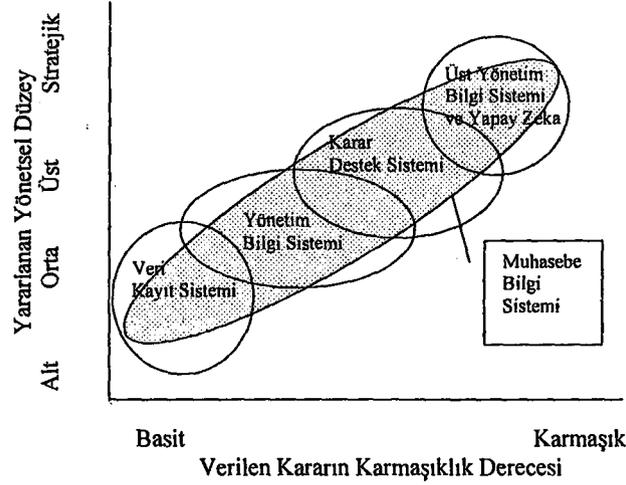
- iv. Üst yönetim bilgi sistemi (Executive information system) ve yapay zeka (artificial intelligence) : Tammen stratejik, oldukça karmaşık, programlanamayan kararların alınmasında kullanılan bilgi sistemleridir. Diğer bilgi sistemlerine oranla daha az karşılaşılr ve tepe noktasındaki yöneticiler tarafından stratejik kararların alınmasında kullanılırlar

Muhasebe bilgi sistemi, bu bilgi sistemleriyle içe içe geçmiş, farklılaşmış bir bilgi sistemidir (Şekil 4.14). Çünkü "Muhasebe bilgi sistemi; bir örgütün veya onun bir alt sisteminin gelirlerinin, varlıkların ve diğer ekonomik olaylarının ölçülmesi, analizi ve öngörülmesiyle ilgili bilgi sistemi bölümüdür."⁷⁰ Özetle işletme bilgi sistemlerinin kapsamına giren ve parasal olarak ifade edilen tüm konular muhasebe bilgi sisteminin içeriğini oluşturmaktadır . Bu nedenle muhasebe bilgi sistemi veri kayıt sistemi, yönetim bilgi sistemi, karar destek sistemi ve özellikle konumuz açısından önem taşıyan yapay zeka şeklinde sıralanan işletme bilgi sistemlerinin de tüm düzeylerini kapsar.⁷¹ Bu bilgi sistemleri ile muhasebe bilgi sisteminin kesiştiği ve ayrıldığı noktaları yakalamak oldukça zordur.

⁷⁰ "Report of the Comiittee on Accounting and Information Systems", **The Accounting Review Supplement**, 1971, pp.289-290. 'dan LEITCH Robert A. DAVIS, Roscoe K., **Accounting Information Systems**, Prentice Hall Int. Inc., 1992, p.7

⁷¹ Ayrıca Bkz: ERDOĞAN Melih- ERDOĞAN Nurten, "Teknolojik Gelişmeler Karşısında Muhasebenin Geleceği", **VI. Ulusal İşletmecilik Kongresi : 2000 li Yıllarda İşletmecilik ve Eğitimi, 12-14 Kasım 1998**, Emel Ofset Matbaacılık Ltd. Şti. Antalya,1998, ss. 251- 267.

Şekil 4. 14 : İşletme bilgi sistemleri ve muhasebe sisteminin yeri



Bu bilgi sistemleri içinde daha çok stratejik ve karmaşık kararların verilmesinde üst yönetim bilgi sistemi ve yapay zeka kullanılmaktadır. Bu alanda uzman sistemler, bulanık mantık, genetik algoritmalar ve yapay sinir ağları, yaygın olarak yer alan yapay zeka teknolojileridir.⁷²

Bunlar içinde yapay sinir ağı, muhasebe bilgi sisteminin bir parçası olarak yer aldığında şu alanlara uygulanmaya elverişlidir:⁷³

- i. İç kontrol yapısındaki açıkları bulma,
- ii. Denetim kanıtlarının yorumlanması,

⁷² GOONATILAKE - TRELEAVEN, A.g.e., p p.8-23.

⁷³ WILKINSON Joseph W.- CERULLO Michael J., **Accounting Information Systems; Essential Concepts and Applications**, Third Ed., John Wiley and Sons Inc., New York, 1997, pp.740-741.

- iii. Denetim kalitesinin yorumlanması,
- iv. Denetim personelinin deęerlendirmelerinin yorumlanması,
- v. Finansal başarısızlığın öngörülmesi,
- vi. Risk oluşumunun öngörülmesi,
- vii. Stoklarla ilgili kestirimler,
- viii. Mamül maliyetinin kestirimi,
- ix. Satış öngörüleri,
- x. Satış fiyatının kestirimi,
- xi. Tahvil fiyatının kestirimi,
- xii. Bütçe rakamlarının kestirimi,
- xiii. Karın kestirimi,
- xiv. Hisse başına karın öngörülmesi,
- xv. Personel performansının öngörülmesi,
- xvi. Kredi riskinin öngörülmesi,
- xvii. Hisse senedi fiyatının öngörülmesi,
- xviii. Birleşme kararlarında tavsiye verme,
- xix. Kişisel finansal planlamada tavsiyeler verme,

- xx. Kredi kartı sahtekarlıklarını belirleme,
- xxi. Çalışanların sahtekarlıklarını belirleme,
- xxii. Yönetim sahtekarlıklarını belirleme.

Bu sorunlar genellikle geleneksel bilgişlem teknolojileri ve uzman sistemler tarafından çözümlenmekte fakat çok zaman ve kaynak gerektirmektedir. Oysa yapay sinir ağları bu tür problemleri kısa zamanda ve dolayısıyla daha ucuza, etkinlikten ödün vermeden çözebilmektedir.⁷⁴

4.8. YAPAY SİNİR AĞININ FİNANSAL BAŞARISIZLIĞI ÖNGÖRMEDE KULLANIMI

Özellikle yapay sinir ağı teknolojisinin geliştiği 1980 'lerden sonraki dönemde yapay sinir ağı çok değişik alanlarda olduğu gibi muhasebe ve finans alanında değişik çalışmalarda kullanılmıştır. Bunlardan bazıları çalışmamız çerçevesinde aşağıda özetlenmişlerdir.

Yapay sinir ağı kullanımına ilişkin bir çalışmada 51 başarısız ve 51 başarılı olmayan işletmeden oluşan örnekleme, birimler sektör kolları ve aktif büyüklükleri açısından eşleştirilmişlerdir. Başarısız işletmeler The Wall Street Journal Index'den 1980-1988 arası dönemde silinen işletmeler arasından, ulaştırma ve finans sektörüne ait işletmeler elenerek seçilmişlerdir. Tüm veriler COMPUSTAT veri tabanından iflasdan 3 yıl öncesini kapsayacak şekilde alınmıştır. Verilerin 25 çifti yapay sinir ağının eğitimi, 26 çifti ise test için kullanılmıştır. Tüm işletmeler için 14 değişken hesaplanmıştır. Bunlardan 13 tanesi finansal

⁷⁴ A.g.e., p.740.

oran, biri de işletmenin finansal başarısızlıktan kaç yıl öncesine ait olduğunu gösteren bir değişkendir.⁷⁵

Araştırma iki aşama olarak tasarlanmıştır: eğitim ve test. 14 değişken öncelikle bir hesap tablosu yazılımıyla aşağıdaki formül kullanılarak normalize edilmiştir.

$$Y=(X-X_1)/(X_2-X_1)$$

Y= Normalleştirilmiş x değeri,

X= Her değişkenin gerçek değeri,

X₁= Her değişkenin minimum değeri,

X₂= Her değişkenin maksimum değeri.

Eğitim verilerinde başarısız işletmeler için 0, başarısız olmayan işletmeler için 1 hedef çıktı olarak kabul edilmiştir. Yapay sinir ağında geri yayılım algoritması ve her neuron için sigmoid fonksiyon kullanılmıştır. Öğrenme katsayısı 0,9 ve momentum terimi 0,65 olarak tespit edilmiştir. Yapay sinir ağında kullanılacak gizli katman sayısının belirlenmesi konusunda belirli bir yöntem bulunmayışı nedeniyle, değişik sayıda gizli katman ve her gizli katmanda değişik sayıda neuronun bulunduğu altı farklı yapay sinir ağı oluşturulmuştur.

Test aşamasında yapay sinir ağının ağırlıkları ve eşik değerleri sabit tutularak örneklemin geri kalan 26 çift işletmeye ait verileri ağdan geçirilmiştir. Ağ başarısız işletmeler

⁷⁵ RAGHUPATI Williananallur - SCHKADE Lawrence L. - RAJU S. Bapi, " A Neural Network Approach to Bankruptcy Prediction", **Proceedings of the IEEE 24th Annual Hawaii International Conference on Systems Science**, 1991, IEEE'den naklen TURBAN227-241.

için 0, başarısız olmayan işletmeler için 1 değeri üretmiştir.

Altı farklı yapıdaki sinir ağından, gizli katmalardan birincisinde 15 ve ikincisinde 2 neuron bulunan ağ, %86 doğru sınıflandırma oranıyla en yüksek başarıyı göstermiştir. En iyi genellemeye bu mimarinin ulaşmasının nedeni finansal oranlar ve finansal başarısızlık arasındaki ilişkinin tek katmanlı bir geriyayılım ağı tarafından çözülemeyecek kadar karmaşık olmasına bağlanmıştır. Çalışmada, yapay sinir ağının bağımsız denetçiler ve diğer ilgililer için iyi bir karar destek sistemi sunduğu sonucuna varılmıştır.⁷⁶

İncelenen bir başka çalışmada, oranlardaki finansal başarısızlığın göstergesi sayılabilecek bir eğilim veya örüntünün yapay sinir ağı tarafından ne ölçüde ortaya çıkarılabileceği araştırılmıştır.⁷⁷

Çalışmada diğer çalışmalardan farklı bir finansal başarısızlık kriteri seçilmiştir. Buna göre, bir bağımsız denetçi tarafından yapılan denetim sonucu işletme finansal başarısızlık potansiyeli taşıdığı sonucuna varılmış (going-concern opinion) ve açıklanmış ise, bu işletme başarısız işletme kabul edilerek örnekleme alınmıştır. Araştırmada örnekleme girecek başarısız işletmeler için bu tip bir kriterin seçilmesinde özel bir amaç güdülmüştür. İflas gibi bir kriter seçildiğinde, iflas tüm bilgi kullanıcıları tarafından bir yıl öncesinde bilinir hale gelmektedir. Çünkü, bağımsız denetçi yaptığı denetimiyle elde ettiği bulgular neticesinde en az bir yıl öncesinde işletmenin finansal başarısızlık potansiyeli taşıdığını açıklamaktadır. Bu durumda, iflasın 1 yıl öncesinde öngören modeli kullanmak bilgi kullanıcıları açısından önemli

⁷⁶ A.g.e.

⁷⁷ COAST K. Pamela-FANT Franklin L, "Recognizing Financial Distress Patterns Using a Neural Network Toll", *Financial Management*, Autumn 1993, pp.142-155.

bir avantaj sağlamamaktadır. Ancak, eğer işletmenin bağımsız denetçiden potansiyel başarısızlık riski taşıdığına ilişkin rapor alacağı öngörülebilirse, bu bilgi kullanıcılarına diğer bilgi kullanıcılarına göre önemli bir avantaj yaratacaktır. Bu şartlar altında 94 başarısız işletme üretim ve hizmet sektöründen, 188 işletme ise sadece üretim sektöründen olmak üzere bir örneklem oluşturulmuştur. Her iki gruba giren işletmeler yarı yarıya bölünerek 47 başarısız ve 94 başarısız olmayan işletmeden oluşan deney ve kontrol grupları elde edilmiştir. Değişken olarak Altman'ın Z katsayısı olarak bilinen modeldeki değişkenler kullanılmıştır.

Model geliştirme sürecinde, işletmelerin finansal başarısızlığa düştüğü yıl ve önceki 3 yıl için toplam dört ayırma analizi ve yapay sinir ağı modeli geliştirilmiştir. Tüm yapay sinir ağı modelleri deney eğitim verileri üzerinde %100 doğru sınıflandırma oranına ulaşmıştır. Her bir yapay sinir ağının eğitimi 1.400'den fazla devir gerektirmiştir. Ayırma analizi ve yapay sinir ağıyla oluşturulan modellerin başarı oranları aşağıdaki tabloda verilmiştir.

Tablo 4. 2 :Yapay sinir ağı ve ayırma analizinin yıllar itibariyle doğru sınıflandırma oranları

| Yıllar | Yapay Sinir Ağı | Ayırma Analizi |
|--------|-----------------|----------------|
| Yıl 0 | % 95 | % 87,9 |
| Yıl-1 | % 92,9 | % 83 |
| Yıl-2 | % 86,2 | % 83,7 |
| Yıl -3 | % 81,9 | % 83,7 |

Modellerin başarısız işletmeleri doğru sınıflandırma oranı ve başarısız işletmeleri doğru sınıflandırma oranları karşılaştırmış ve tüm yıllarda yapay sinir ağı ayırma analizi modelinden daha yüksek doğru sınıflandırma oranı göstermiştir. Bu modellerin doğru sınıflandırma oranları arasındaki farkın anlamlılık test yapılmış ve 1 yıl haricinde diğer tüm

yıllarda oranlar arasındaki fark %5 anlamlılık düzeyinde anlamlı bulunmuştur.⁷⁸

Yapay sinir ağı ile ayırma analizinin finansal başarısızlığın öngörülmesinde kullanılarak, performanslarının ölçüldüğü başka bir çalışmada değişken olarak Altman'ın Z katsayısı olarak bilinen modeldeki oranlar kullanılmıştır. Örnekleme giren işletmelere ait finansal oranlar 1975-1982 arası dönemlerdeki muhasebe raporlarından elde edilmiştir. Örneklem 65'i başarısız ve 64'ü başarısız olmayan 129 işletmeden oluşmaktadır. Başarısız işletme kriteri olarak iflas seçilmiştir. Finansal başarısızlığın öngörülmesi için kullanılan finansal bilgiler, başarısızlıktan bir önceki yılın verileri olduğu için modellerin ürettiği öneriler bir yıl öncesi için geçerlidir.⁷⁹

Ayırma analizi ve yapay sinir ağı modellerinin doğru sınıflandırma başarılarının araştırılması için örneklem deney ve kontrol grubu olarak iki alt kümeye ayrılmıştır. Bunlardan ayırma analizi fonksiyonun geliştirilmesi ve yapay sinir ağının eğitilmesi için deney grubu verileri, ayırma analizi fonksiyonunun geçerlilik analizi ve yapay sinir ağının test edilmesi için kontrol grubu verileri kullanılmıştır. Yapay sinir ağı terminolojisinde test, yapay sinir ağı modelinin eğitim verileri dışındaki verilerdeki hata oranının ölçülmesi anlamındadır ve istatistiksel anlamda yapılan geçerlilik analizine karşılık gelmektedir.⁸⁰

Çalışmada iki soru cevaplanmaya çalışılmıştır. Birincisi tekniklerden herhangi birinin, örneklemedeki başarısız işletme oranından olumsuz etkilenip etkilenmediği; ikincisi temel oran olarak ifade edilen başarısız işletme / başarısız olmayan işletme oranının deney grubu verileri

⁷⁸ A.g.e.

⁷⁹ WILKSON Rick L. - SHARDA Ramesh, "Bankruptcy Prediction Using Neural Networks", **Decision Support Systems**, V:11, pp.545-557

⁸⁰ A.g.e.

ile kontrol grubu verilerinde farklılaşmasının etkisinin ne olacağıdır. İkinci soru özellikle gerçek hayattan farklı bir temel orana sahip verileriyle geliştirilen ayırma analizi modelinin veya yapay sinir ağı modelinin, farklı temel oran içeren gerçek hayattaki veriler üzerinde nasıl bir performans göstereceğinin incelenmesini amaçlamaktadır. Bu doğrultuda aşağıdaki oranlara sahip dokuz farklı veri seti oluşturulmuştur.

Tablo 4. 3 :Değişik temel oranına sahip veri setleri

| Deney grubu temel oranı | Kontrol grubu verilerindeki temel oran | | |
|----------------------------|---|------------|------------|
| | %50/ %50 | %80/ 20 | %90/ 10 |
| %50/ %50 | | | |
| Eğitim | 44/44 | 44/44 | 44/44 |
| Test | 20/20 | 20/5 | 20/2 |
| %80/%20 | | | |
| Eğitim | 44/11 | 44/11 | 44/11 |
| Test | 20/20 | 20/5 | 20/2 |
| %90/%10 | | | |
| Eğitim | 44/5 | 44/5 | 44/5 |
| Test | 20/20 | 20/5 | 20/2 |

Kaynak : Rick L. WILKSON - Ramesh SHARDA, "Bankruptcy Prediction Using Neural Networks", **Decision Support Systems**, V:11,p.

Ayrma analizi modelinin oluşturulmasında, önsel olasılıkların belirlenmesinde verilerdeki grup oranlarından yararlanan SYSTAT adlı yazılım kullanılmıştır. Yapay sinir ağı, girdi katmanında 5 neuron, tek gizli katmanda 10 neuron ve çıktı katmanında 2 neuronla; BRAINMAKER adlı yazılım kullanılarak oluşturulmuştur. Öğrenme algoritması olarak geriyayılım algoritması kullanılmıştır. Eğitim için çıktı katmanındaki iki neuronun hedef çıktıları; birinci neuron başarısız işletmeler için 0, başarısız olmayan işletmeler için 1; ikinci

neuron başarısız işletmeler için 1, başarısız olmayan işletmeler için 0 değeri alacak şekilde kodlanmışlardır.⁸¹ Deney grubu veriler üzerinde geliştirilen modellerin doğru sınıflandırma oranları aşağıdaki gibidir:

Tablo 4. 4 :Deney grubu verilerde ayırma analizi ve yapay sinir ağı modellerinin doğru sınıflandırma oranları

| Deney Grubu Temel Oranı | Deney grubu verilerde ortalama doğru sınıflandırma oranı | |
|----------------------------|--|-------------------|
| | Yapay sinir ağı | Ayırma analizi |
| %50/%50 | 100 | 88,65 |
| %80/%20 | 100 | 90,33 |
| %90/%10 | 100 | 94,59 |

Kaynak : Rick L. WILKSON - Ramesh SHARDA, "Bankruptcy Prediction Using Neural Networks", **Decision Support Systems**, V:11, p.

Bu modellerin kontrol verileri üzerindeki geçerlilik analizi ve test sonuçları aşağıdadır:

Tablo 4. 5 :Kontrol grubu verilerde ayırma analizi ve yapay sinir ağı modellerinin doğru sınıflandırma oranları

| Deney grubu temel oranı | Kontrol verilerindeki temel oranı | | | | | |
|-------------------------------|-----------------------------------|-------------------|--------------------|-------------------|--------------------|-------------------|
| | %50/%50 | | %80/%20 | | %90/%10 | |
| | Yapay sinir ağı | Ayırma analizi | Yapay sinir ağı | Ayırma analizi | Yapay sinir ağı | Ayırma analizi |
| %50/%50 | 97,5 | 88,25 | 95,6 | 91,8 | 95,68 * | 93,32 * |
| %80/%20 | 82 | 75,875 | 91 | 89 | 95,68 * | 91,59 * |
| %90/%10 | 72,625 | 72 | 86,25 | 85,8 | 94,55 | 91,81 |

(*) %5 Anlamlılık düzeyinde, diğerleri oranlar %1 anlamlılık düzeyinde farklıdır

Kaynak : Rick L. WILKSON - Ramesh SHARDA, "Bankruptcy Prediction Using Neural Networks", **Decision Support Systems**, V:11, p.

⁸¹ A.g.e.

Tablo 4.5'de görüldüğü gibi deney grubu verilerde temel oran ne olursa olsun yapay sinir ağının kontrol verilerindeki doğru sınıflandırma oranı ayırma analizinden yüksek çıkmıştır. Ancak yapay sinir ağı ve ayırma analiziyle geliştirilen modeller, kontrol veri grubundaki temel oran ne olursa olsun en iyi performansı eğitim verilerinin %50/% 50 temel orana sahip olduğu durumda göstermişlerdir.⁸²

Finansal başarısızlığın öngörülmesinde yapay sinir ağı ile Logit tekniğinin doğru sınıflandırma performanslarını karşılaştıran bir araştırmada; yapay sinir ağının, değişenler arasında çoklu korelasyon bulunduğu durumlarda istatistik tekniklere karşı daha uygun bir çözüm aracı olarak tanıtılmaktadır.⁸³

Çalışmada kullanılan 100 başarısız ve 100 başarısız olmayan işletmeden oluşan 200 birimlik örneklemdaki birimler işletme büyüklüğü ve coğrafya bazında eşleştirilerek, yapay sinir ağı modelinin ve Logit modelinin geliştirilmesinde kullanılmışlardır. Daha sonra iki farklı kontrol grubu oluşturularak bunlar geçerlilik analizi için kullanılmışlardır . Bu kontrol gruplarından birinde işletmelerin 6, 12 ve 18 ay önceki finansal raporlarına ait veriler bulunmaktadır ve birimler eşleştirilmiş durumdadırlar. Bunlardan 58 çift işletmenin 6 ay önceki, 47 çift işletmenin 12 ay ve 24 çift işletmenin 18 ay önceki finansal tabloları elde edilmiştir. İkinci bir kontrol grubu yine geçerlilik analizi için, fakat 75 başarısız işletme ve 329 başarısız olamayan işletmeyle iki yıl önceki finansal bilgiler kullanılarak oluşturulmuştur.

⁸² A.g.e.

⁸³ SALCHENBERGER Linda M. - CINAR E Mine - LASH Nicholas A., " Neural Networks : A New Tool for Predicting Thrift Failures", *Decision Sciences*, V:23, No:4, (July/August,1992),pp.889-916.

Bu ikinci kontrol grubu verilerin kullanılarak ikinci bir geçerlilik analizinin yapılmasının nedeni elde edilen modellerin gerçek hayata yakın oranda başarısız - başarısız olmayan işletme içeren verilerle göstereceği performansın araştırılmasıdır.⁸⁴

Yapaya sinir ağı modelinin geliştirilmesinde, bir çok diğer çalışmada olduğu gibi deneme yanılma şeklinde bir süreç izlenmiştir ve birden fazla katmanlı modeller iyi sonuç vermediği için tek katmanlı modellerle araştırmaya devam edilmiştir. Ayrıca gizli katmanda kullanılan neuron sayısının artırılmasının, ağıın sınıflandırma performansını arttırdığı, ancak ağıın test verileri üzerindeki doğru sınıflandırma performansının ise düştüğü önemle vurgulanmıştır. Sonuçta elde edilen modelde girdi katmanında 5 neuron, gizli katmanda 3 neuron ve çıkış katmanında 1 neurondan oluşan bir ağ yapısı oluşturulmuştur. Eğitim verilerinde hedef çıktılar başarısız işletmeler 0, başarısız olmayan işletmeler için ise 1 ile kodlanmışlardır. Genelleştirilmiş delta algoritması ve hatanın geriye yayıldığı bir ağ yapısı (geriyayılım algoritması) kullanılmıştır. Geçiş fonksiyonu olarak da sigmoid fonksiyon tercih edilmiştir. Bu özelliklerdeki yapay sinir ağı NeuralWare, Inc., adlı bir yazılı şirketinin ürettiği Neural Works Explorer adlı yazılım ve 386 tipi bir bilgisayar kullanılarak elde edilmiştir. Bu yazılımın kullanılmasına neden olarak da, yazılımın öğrenme aşamasında öğrenme oranını ve momentum terimini değiştirmeye izin vermesi gösterilmiştir. Eğitim verileri içinde oran olarak yer almayanlar değerler, yazılım tarafından 0-1 arasında otomatik olarak ölçeklendirilmiştir. Bu öğrenme algoritmasının performansının artmasına ve eğitimin süresinin kılmasına yardımcı olmaktadır. Eğitim sırasında öğrenme oranı azaltılmış ve momentum ise artırılmıştır. Öğrenme oranının, eğitim hatasında büyük salınımlara neden

⁸⁴ A.g.e.

olmayacak kadar büyük olmasına özen gösterilmiştir. Yapay sinir ağının eğitimi, eğitim hatasında düşme trendi duruncaya kadar devam edilmiştir. Bu 40.000 devir aşıldıktan sonra gerçekleşmiştir.

Bu çalışmada özellikle Logit modeldeki değişkenler arasındaki çoklu korelasyon, korelasyon matrisiyle kontrol edilmiştir. Ayrıca temel bileşenler analizi uygulanmış ve değişkenler arasında çoklu korelasyonun önemli sorun çıkarmayacağı test edilmiştir.

Logitle elde edilen modelde kopuş noktası olarak daha önce 0,5 kabul edilmiştir. Ancak daha sonra Tip I hatasının daha düşük çıktığı için kopuş noktası 0,2 ye çekilmiştir. Buna paralel olarak 0,5 ve 0,2 eşik değerli iki yapay sinir ağı geliştirilmiştir. Yapay sinir ağı her iki kopuş noktasında da finansal başarısızlıktan 6, 12 ve 18 ay önce Logit den daha yüksek doğru sınıflandırma oranına ulaşmıştır (Tablo 4.6) .

Tablo 4. 6 :Logit ve Yapay Sinir Ağının Doğru Sınıflandırma Oranları

| 0,5 Kopuş noktasıyla | Logit % | Yapay Sinir Ağı % |
|----------------------|---------|-------------------|
| Eğitim Deney Setinde | 93.5 | 97 |
| 6 ay öncesi | 87.8 | 92.2 |
| 12 ay öncesi | 85.9 | 92.4 |
| 18 ay öncesi | 83.3 | 91.7 |
| 0,2 Kopuş noktasıyla | | |
| Eğitim Seti | 83 | 92.5 |
| 6 ay öncesi | 87.1 | 89.7 |
| 12 ay öncesi | 85.9 | 92.4 |
| 18 ay öncesi | 85.4 | 91.7 |

Kaynak : SALCHENBERGER Linda M.- E Mine CINAR - Nicholas A. LASH; " Neural Networks : A New Tool for Predicting Thrift Failures", **Decision Sciences**, V:23, No:4,p. (July/August,1992) den değiştirilerek alınmıştır.

Yapay sinir ağı ve Logit ile elde edilen sonuçların arasındaki farkın istatistiksel olarak anlamlı olup olmadığının araştırılması için Ki-Kare testi yapılmıştır ve %10 anlamlılık düzeyinde 0,5 kopuş noktasında anlamlı olduğu anlaşılmıştır. Ayrıca Logit'in doğru olarak sınıflandırdığı ancak yapay sinir ağının yanlış sınıflandırdığı herhangi bir işletme olmadığı da vurgulanmaktadır.⁸⁵

Modellerin 75 başarısız ve 329 başarısız olmayan işletmeden oluşan ikinci kontrol grubu veriler üzerindeki doğru sınıflandırma oranları ise aşağıdır.

Tablo 4. 7 : Logit ve yapay sinir ağının değişik kopuş noktalarıyla doğru sınıflandırma oranları

| | Logit % | Yapay Sinir Ağı % |
|----------------------|------------|----------------------|
| 0,5 Kopuş Noktasında | 94.3 | 96.8 |
| 0,2 Kopuş Noktasında | 92.3 | 95.8 |

Kaynak : SALCHENBERGER Linda M.- E Mine CINAR - Nicholas A. LASH, " Neural Networks : A New Tool for Predicting Thrift Failures", **Decision Sciences**, V:23, No:4, p. (July/August,1992) den değiştirilerek alınmıştır.

Çalışmada varılan sonuçlar şu şekilde özetlenebilir:⁸⁶

- i. Yapay sinir ağı modeli tüm durularda Logit tekniğiyle elde edilen modelden daha yüksek doğru sınıflandırma oranına ulaşmıştır.

⁸⁵ A.g.e.

⁸⁶ A.g.e.

- ii. Çalışmada 0,5 kopuş noktasının yanında 0,2 kopuş noktasıyla da modellerin sonuçları değerlendirilmiştir. Bu durumda yapay sinir ağı modeli ve Logit ile elde edilen doğru sınıflandırma başarısı toplamda artarken, Tip I hatası azalma, Tip II hatası artma eğilimi göstermiştir.
- iii. Çalışmada önceki çalışmalara paralel şekilde yapay sinir ağının, başarısız-başarısız olmayan işletme oranının gerçek hayattaki oranlara yaklaştığında da doğru sınıflandırma başarısını sürdürmektedir.
- iv. Üç katmanlı bir yapay sinir ağı [tek gizli katmanlı] Logit'den daha iyi öngörü başarısı göstermektedir.

Yukarıda elde edilen sonuçlar yanında, çalışmada sıralanan sınırlılıkları da belirtilmelidir:

- i. Yapay sinir ağı mimarilerinin seçilmesi konusunda henüz belirlenmiş bir yöntem bulunmamaktadır. Bu da geliştirilen mimarilerin en uygun mimariler olup olmadığı konusunu tartışmalı hale getirmektedir. Ayrıca yapay sinir ağının yanlış parametre seçimine karşı hassas olduğu bilinmektedir. Ancak geriyayılım algoritması örüntü tanıma ve sınıflandırma problemleri için uygun bir çözüm oluşturmaktadır.
- ii. Yapay sinir ağı teknolojisiyle elde edilen modeller kapalı bir kutu içinde kalır ve nasıl, niçin gibi modele ilişkin bazı sorular yanıtsız kalır.

Yapay sinir ağı ile ayırma analizinin doğru sınıflandırma başarılarının incelendiği diğer çalışmanın yazarlarından biri, ayırma analizini finansal başarısızlık alanında ilk

uygulayan Edward I. Altman'dır. Bu çalışmada geliştirilen değişik yapay sinir ağı modellerinden bazılarında eğitimin 1.000 devirde kesilmesi, yapay sinir ağının ayırma analizinden daha az sayıda değişken kullanılarak eğitilmesi gibi bazı "farklı yöntemler" kullanıldığı dikkat çekmektedir. Çalışmanın sonuç bölümünde yapay sinir ağı modelinin ilgi çekici, ümit verici olduğu belirtilerek; ayırma analizine yakın veya üstün doğru sınıflandırma sonuçları ürettiği, fakat genel olarak yapay sinir ağının bazı düzensiz davranış özellikleri göstermesi gibi nedenlerle ayırma analiziyle bütünleştirilmesi önerilmektedir.⁸⁷

Yapay sinir ağının muhasebe araştırmalarında kullanıma ilişkin bazı eleştiriler de bulunmaktadır. Bu eleştiriler yapay sinir ağıyla elde edilen modellerin henüz insanlar tarafından yorumlanamadığı dikkat çekilerek, yapay sinir ağının ancak eldeki istatistik tekniklerin kullanılmasının olanaksız olduğu karmaşık ve kuramsal bilginin bulunmadığı durumlarda kullanılması önerilmektedir. Yazarlar bir bilimsel çalışmada elde edilen modelin anlaşılmasının çok önemli olduğunu belirterek, yapay sinir ağının bu şekilde kullanımını eleştirmektedirler.⁸⁸ Ancak bilimsel araştırmaların birincil hedefinin geleceği öngörmek ve doğayı kontrol altına almak olduğu dikkate alınır, yapay sinir ağının daha yüksek doğru sınıflandırma başarısıyla bu amaca daha fazla katkıda bulunduğu söylemek yanlış olmayacaktır. Ayrıca finansal başarısızlığı öngörmeye kullanılan istatistik tekniklerin varsayımlarının çiğnenerek elde edildiği göz önüne alındığında, yapay sinir ağı modellerinin "kara kutu içinde kalması" sorunu önemini yitirdiği düşünülebilir. Yapay sinir ağı alanındaki

⁸⁷ ALTMAN I Altman- MARCO G.- VARETTO F., " Corporate Distress Diagnosis : Comparisons Using Linear Discriminant Analysis and Neural Networks", *Journal of Banking and Finance*, V:18 (1994), pp.505-529.

⁸⁸ TRIGUEIROS Duarte- TAFLEER Richard, " Neural Networks and empirical Research in Accounting", *Accounting and Business Research*, V:26, N:4,(1996), pp.347-355.

bilimsel çabaların yoğunluğu, ağın içinde kalan ağırlık değerlerinin yakın bir gelecekte yorumlanabileceği konusunda umut vermektedir. Bu çabaların en uygun yapay sinir ağı mimarisinin seçilmesi için gerekli yöntemi geliştireceğini beklememek için neden yoktur.





BESİNCİ BÖLÜM

FİNANSAL BAŞARISIZLIĞIN ÖNGÖRÜLMESİNDE YAPAY SINIR AĞI

KULLANIMINA İLİŞKİN AMPİRİK BİR ÇALIŞMA

BEŞİNCİ BÖLÜM

FİNANSAL BAŞARISIZLIĞIN ÖNGÖRÜLMESİNDE YAPAY SİNİR AĞI KULLANIMINA İLİŞKİN AMPİRİK BİR ÇALIŞMA

5.1. ÇALIŞMADA KULLANILAN ÖRNEKLEM

Bu çalışmanın kapsamını, Türkiye'de 1983-1997 yılları arasındaki dönemlerde SPK'ya tabi ve/veya İstanbul Menkul Kıymetler Borsası'nda (İMKB) işlem gören sanayi, ticaret ve hizmet işletmeleri oluşturmaktadır. Çalışmanın kapsamının bu şekilde belirlenmesindeki temel etken Türkiye'de finansal başarısızlığa düşmüş işletmelere ait bilgilerin bulunmasındaki zorluktur. Yapılan araştırmada Sanayi ve Ticaret Bakanlığı, Adalet Bakanlığı ve Devlet İstatistik Enstitüsü'nde finansal başarısızlığa düşmüş işletmelerle ilgili düzenli bir veriye rastlanmamıştır. Sadece Merkez Bankası Risk Santralizasyon Merkezinde bankalardan kredi kullanan işletmelerin aldıkları kredi ve risk durumlarına ilişkin ayrıntılı bilgi bulunmasına rağmen, bu bilgiler kanun gereği sır kapsamında değerlendirilmekte ve açıklanmamaktadır. Bu tür veri bulma zorlukları çalışmada, kamuya açık nitelikteki SPK ve İMKB'ye tabi

işletmelerin finansal tablolarıyla yetinilmesi sonucunu doğurmuştur. Ayrıca bu işletmelere ait muhasebe sistemlerinin ve bilgilerinin SPK ve İMKB tarafından sıkı takip altında olması nedeniyle taşıdıkları güvenilirlik, bu işletmelerin finansal durumunun ülkedeki çok sayıda bilgi kullanıcıyı yakından ilgilendiriyor olması, çalışmamızda SPK ve İMKB' den elde edilen verileri kullanmada belirleyici rol oynamıştır.

Bu kapsam dahilinde değerlendirilen işletmeler arasından özellikle finansal kuruluşlar, holdingler, ulaşım sektörü işletmeleri, çok farklı finansal karakteristikler göstermelerinden dolayı örneklem dışı bırakılmıştır. Ayrıca yeni kurulmuş işletmeler, kuruluşlarının ilk yıllarında finansal başarısızlığa çok yakın belirtiler göstermelerine rağmen, bu durumun yeni kurulan işletmelerin doğasında bulunması ve genellik geçici olması nedeniyle kapsamdan çıkarılmışlardır. İşletme büyüklüğü açısından çok küçük aktif toplamına sahip işletmelerle, hiç veya çok az satış rakamı elde eden işletmeler de kapsamdan çıkartılacak işletmelere dahil edilmiştir. Yapay sinir ağı teknolojisiyle çalışırken sorun yaratmayacak, ancak ayırma analizi tarafından veri olarak kullanıma uygun olmayan (bazı kalemleri bilinmeyen finansal raporlara sahip işletmeler) işletmeler, yapay sinir ağı ve ayırma analizinin arasında başlangıçta bir eşitsizlik yaratmamak için örneklemden çıkarılmışlardır.

İşletmelerin seçiminde sanayi, ticaret ve hizmet sektörü ayrımı, finansal başarısızlık kriterine uyan işletme sayısının sınırlılığından dolayı olanaklı olmamıştır. Böyle bir ayrımın yapılmaması, araştırmada geliştirilen modelin başarısını olumsuz yönde etkileyebileceği düşünülebilirse de, elde edilen model, sadece bir sektörde başarılı sonuçlar üreten modele göre daha geçerli sonuçlar üretecektir.

Finansal başarısızlığa düşmüş işletmelerin seçiminde, birinci bölümde her biri ayrıntılarıyla incelenen aşağıdaki kriterler kabul edilmiştir. Ancak ele alınan işletmelerin

çoğunun bu kriterlerden birkaçına birden girdiği gözlemlenmiştir.

- i. İflas,
- ii. Sermayesinin yarısını kaybetmiş olması (dönem ve geçmiş yıllar zararlarının toplamı işletmenin sermayesinin yarısını aşması),
- iii. Aktif tutarının %10'nu kaybetmiş olması (dönem ve geçmiş yıllar zararlarının aktif toplamının %10'nu bulması),
- iv. Üç yıl üst üste zarar etmiş olmak,
- v. Borç ödeme zorluğu içine düşmüş olma,
- vi. Üretimi durdurma,
- vii. Borçların aktifi aşması.

Başarısız olmayan işletmelerin seçimi, yukarıdaki finansal başarısızlık kriterlerine uymayan işletmeler arasından yapılmıştır. Bu nedenle, bir yıl zarar etmiş ancak sonrasında faaliyetini normal olarak sürdürmüş işletmeler de veri kümesinde bulunmaktadır. Veriler arasında bu tür işletmelerin bulunması, geliştirilecek modellerin herhangi bir yılda zarar etmiş işletmelerle, finansal başarısızlık durumundaki işletmeleri daha hassas biçimde ayırabilmesine de olanak tanımaktadır.

Bu kapsam ve kriterler bazında 53'ü finansal başarısız, 53'ü finansal başarısız olmayan, toplam 106 işletmeden oluşan bir örneklem elde edilmiştir. Başarısız işletmelerle, başarısız olmayan işletmelerin eşit sayıda ele alınmasında iki faktör rol oynamıştır. Birincisi ayırma analizinde başarısız işletmelerle, başarısız olmayan işletmelerin önsel olasılıklarının bilinmesi gerekmektedir. Ancak ülkemizde finansal başarısızlığa düşen işletmelerle ilgili

herhangi bir sağlıklı istatistik tutulmadığı için, bu önsel olasılıklar bilinmemektedir. Böyle durumlarda, önsel olasılıkların %50-%50 alınabilmesi için, başarısız işletmelerle, başarısız olmayan işletmelerin sayısı eşitlenmektedir. İkinci önemli faktör ise yapay sinir ağlarıyla ilgilidir. Yapay sinir ağları en iyi öğrenmeyi gerçekleştirebilmeleri için, eğitim verileri içindeki değişik durumların eşit olarak temsil edilmesi gerekmektedir.

Çalışmada geliştirilen modellerin, işletmeleri finansal başarısızlığa düşmeden 1 yıl öncesinde tanımlayabilmeleri amaçlanmıştır. Bu nedenle finansal başarısızlığa düşen işletmelerin, finansal başarısızlıktan 1 yıl önceki finansal tablo bilgileri, verilerin hesaplanmasında temel alınmıştır. Bununla birlikte finansal başarısızlık kriterlerinden "üç yıl üst üste zarar etme" kriterine uyan işletmelerin, ancak üçüncü yılda kritere tam uygunluk göstermeleri nedeniyle, üst üste zarar ettikleri ikinci yıl verileri temel alınmıştır.

Elde edilen verilerden 70 ve 36 işletmeden oluşan deney ve kontrol grubu şeklinde iki alt veri kümesi oluşturulmuştur. Bunlardan birincisi ayırma analizi fonksiyonunun geliştirilmesi ve yapay sinir ağının eğitilmesi için kullanılırken; ikincisi ayırma analiziyle elde edilen ayırma fonksiyonunun geçerlilik analizi ve yapay sinir ağının testi için kullanılmıştır.

Çalışmada kullanılan işletmelerin listesi Ek-1'de verilmiştir. Bu listede durum sütununda "0" ile gösterilen işletmeler finansal başarısız, "1" ile gösterilen işletmeler finansal başarısız olmayan işletme grubuna aittirler.

Çalışmada geliştirilen modeller değişken olarak finansal oranları kullanmaktadır. Teorik olarak hesaplanabilecek oran sayısı yüzlerle ifade edilebilir. Bunlar içinde, yazında üzerinde birleşilen, önemli olduğu kabul edilen, yaygın olarak kullanılan, kolay hesaplanabilir, oranlar seçilmiştir. Bu oranları genel bilgi üreten, ayrıca sektör farklılıklarından, işletme büyüklüğünden ve işletme politikalarından etkilenmeyen oranlar

olmalarına dikkat edilmiştir. Yapay sinir ağı modelinin geliştirilmesinde kullanılan yazılımın en fazla 15 değişkene izin vermesinden dolayı, kullanılacak oran sayısı 15 ile sınırlandırılmıştır.

Bu oranlar şunlardır:

X1: Cari oran = Dönen Varlıklar / Kısa Vadeli Yabancı Kaynaklar

X2 : Likidite Oranı = Dönen Varlıklar - Stoklar / Kısa Vadeli Yabancı Kaynaklar

X3 : Kısa Vadeli Yabancı Kaynaklar / Özsermaye

X4 : Toplam Borç / Özsermaye

X5 : Toplam Borç / Toplam Varlık

X6 : Sabit Giderleri Karşılama Oranı = Dönem Karı + Finansman Giderleri / Finansman Giderleri

X7 : Hazır Değerler Devir Hızı = Net Satışlar / Hazır Değerler

X8 : Dönen Varlıklar Devir Hızı = Net Satışlar / Dönen Varlıklar

X9 : Maddi Duran Varlıklar Devir Hızı = Net Satışlar / Maddi Duran Varlıklar

X10 : Özsermaye Dönüş Hızı = Net Satışlar / Özsermaye

X11 : Aktif Dönüş Hızı = Net Satışlar / Aktif Toplamı

X12 : Brüt Kar Oranı = Brüt Satış Karı / Net Satışlar

X13 : Faaliyet Karı Oranı = Faaliyet Karı / Net Satışlar

X14 : Dönem Karı Oranı = Dönem Karı / Net Satışlar

X15 : Özsermayenin Amortismanı Oranı = Dönem Karı / Özkaynaklar

Örnekleme yer alan işletmelerin tamamı için yukarıdaki oranların hesaplanmasında

bir veritabanı yazılımı kullanılmıştır. Böylelikle hemen, hemen tüm yazılımlar tarafından okunabilen bir veritabanı oluşturulmuştur.

Oranların hesaplanmasında kullanılan verilerin bulunduğu finansal tablolar SPK tarafından bir örneklige kavuşturulduğu için verilerde fazla düzenleme yapma gereği ortaya çıkmamıştır. Ancak 1988 yılından önceki finansal tablolarda brüt satış karından faaliyet giderleri düşüldükten sonra bulunan "işletme karı" kalemi ve İMKB tarafında yayınlanan İMKB tabi işletmelerin yıllık finansal tablolarındaki "Esas Faaliyet Karı veya Zararı" kalemi, Tekdüzen Hesap Planı 'na uygun olarak "Faaliyet Karı veya Zararı" olarak düzeltilmiştir.

Bazı işletmelerin sadece özet finansal tabloları bulunabildiği için; finansal analizdeki tutarlılık ilkesine sadık kalınarak, tüm işletmelerin özet finansal tabloları kullanılmıştır. Bu durum oranların hesaplanmasında net değerlerin kullanılmasını sonucunu doğurmuştur.

Hesaplanan oranlar Ek-2'de toplu olarak verilmiştir.

5.2. ÇALIŞMADA GELİŞTİRİLEN MODELLER

Bu çalışmada, daha önce de belirtildiği gibi, ayırma analizi tekniğiyle elde edilen modele, yapay sinir ağı teknolojisiyle elde edilen modellerin alternatif olabileceği öne sürülmektedir. Bu doğrultuda ayırma analizi ve yapay sinir ağıyla model geliştirerek, bu modellerin doğru sınıflandırma başarıları karşılaştırılacaktır. Karşılaştırma neticesinde elde edilen bulgular doğrultusunda aşağıda oluşturulan iki hipotez test edilecektir:

$$H_0 : P_{(YSA)} = P_{(AA)}$$

$$H_a : P_{(YSA)} > P_{(AA)}$$

H_0 , yapay sinir ağıyla elde edilecek doğru sınıflandırma oranının $P_{(YSA)}$ ayırma

analiziyle elde edilecek doğru sınıflandırma oranına $P_{(AA)}$ eşit olacağını ileri süren sıfır hipotezidir. H_a , yapay sinir ağıyla elde edilecek doğru sınıflandırma oranının $P_{(YSA)}$, ayırma analiziyle elde edilecek doğru sınıflandırma oranından büyük olacağını ileri süren alternatif hipotezdir.

Çalışmada elde edilen bulgularla , % 5 anlam düzeyinde, H_0 hipotezi red edildiğinde, ayırma analizi tekniğine alternatif olarak yapay sinir ağının kullanılabilceği; aksi halde H_0 hipotezi kabul edilerek, bu çalışmada elde edilen bulguların, yapay sinir ağını ayırma analizine alternatif bir model olarak desteklemediği sonucu çıkacaktır.

Ayırma analizi ve yapay sinir ağının doğru sınıflandırma başarılarının karşılaştırılması için; 70 işletmeden oluşan veri kümesi kullanılarak biri ayırma analizi, diğeri yapay sinir ağıyla oluşturulmuş iki model geliştirilmiştir. Daha sonra bu modeller geçerlilik analizi ve test için 36 birimlik ikinci bir veri kümesindeki doğru sınıflandırma performansları ölçülmüştür.

5.2.1. Ayırma Analizi Modelinin Geliştirilmesi

Ayırma analizinin değişken sayısının çok olması durumunda bilgisayar yardımı olmaksızın yapılması oldukça zordur. Bu nedenle ayırma analizinin yapılması ve ayırma analizi fonksiyonunun geliştirilmesi için sosyal bilimlerdeki araştırmalarda sıklıkla kullanılan bir istatistik yazılımı olan SPSS' den yararlanılmıştır. ¹ 70 işletmeye ait oranlardan oluşan veri setiyle elde edilen sonuçlar Ek-3'de verilmiştir.

Ayırma analiziyle elde edilen sonuçlar incelendiğinde, "Canonical Discriminant

¹ SPSS for Windows, Release 6.1 (Standart Version), Copyright © SPSS Inc., 1989-1994.

Functions" başlığı altında yer alan özdeğer (eigenvalue) değeri, ayırma analizinin ne kadar değerli olduğunu açıklayan bir istatistiktir. Özdeğer "0" olduğunda, ayırma analizinin herhangi bir ayırıcılık özelliğinin olmadığını gösterir. Bu değerın üst değeri bulunmamakla beraber 0.40'dan büyük değerlerin mükemmel olduğu kabul edilir. Çalışmada özdeğerin 0,8044 değerini aldığı ve ayırma analizinin oldukça iyi ayırıcılık sağladığı söylenebilir. Yine bu başlık altında yer alan kanonik korelasyon katsayısı (Canonical Corr) ayırma analizi skorları ile gruplar arasındaki ilişkinin derecesini gösteren bir istatistik olup, 0-1 arasında değer alır. "0" ayırma analizi skoru ile gruplar arasında bir ilişkinin olmadığını, "1" ise tam bir ilişkiyi ifade eder. Son olarak Wilks' Lambda değeri grup ortalamalarının farklı olup olmadığını göstergesidir. Büyük lambda değeri grup ortalamalarının farklı olmadığını, küçük lambda değeri ise grup ortalamalarının farklı olduğunu ortaya koyar. Bu değer ne kadar küçükse fonksiyonun ayırt edici gücü o kadar artmaktadır.

"Standardized canonical discriminant function coefficients" başlığı altında yer alan değişkenler ve katsayıları, ayırma analizi sonucu elde edilen fonksiyona, ilgili değişkenin göreceli katkısını gösterir. Buradaki büyük katsayılar büyük katkıyı, küçük katsayılar küçük katkıyı gösterirken, katsayıların işaretinin özel bir anlamı bulunmamaktadır. Bu nedenle negatif işarete sahip katsayıların fonksiyona negatif yönde katkısı olduğu şeklinde yorumlanmamaları gerekir.

Çalışmanın varsayımları arasında grup kovaryanslarının eşitliği varsayımsal olarak kabul edildiği için, grup kovaryanslarının eşitliğine ilişkin hipotez testini içeren Box's M testi sonuçları değerlendirilmeyecektir.

Elde edilen sonuçlar arasındaki en önemli bilgilerden birisi "Unstandardized canonical discriminant function coefficients" başlığı altındaki ayırma analizi fonksiyonudur. Burada yer

alan deęişkenler ve sabit, ayırma analizinde kullanılacak deęişkenler ve sabit deęer olup; karşılarında bu deęişkenlerin katsayıları ve sabitin deęeri yer alır. Çalışmada elde edilen ayırma analizi fonksiyonu aşağıdaki gibidir:

$$Z = X_{13} 2.12362270 + X_{15} 1.6227019 + X_5 -2.9324167 + 1.1287615$$

Bu ayırma fonksiyonuyla elde edilen "ayırma skoru", "Canonical discriminant functions evaluated at group means (group centroids)" başlığı altındaki, grup ortalamaları (y^0 ve y^1) deęerleri dikkate alınarak deęerlendirilir. Grup ortalamalarının ortalaması, ayırma fonksiyonunun grup üyelerini atamada kullanılacak kritik deęeri vermektedir.

$$y_c = \frac{y^0 + y^1}{2}$$

Çalışmada bu deęer

$$y_c = \frac{-0.884 + 0.884}{2} = 0$$

dır.

Ayırma analiziyle elde edilen fonksiyon geęerlilik analizinin yapılabilmesi için kontrol veri kümesinde bulunan işletmeler ve oranları için uygulanmıştır. Bunun için her işletme için ayırma fonksiyonuyla ayırma skorları hesaplanarak gruplara atamaları yapılmıştır. Ayırma fonksiyonunun kontrol veri kümesine uygulanmasıyla elde edilen ayırma skorları, atandıkları gruplar ve işletmelerin ait oldukları gruplarla olan karşılaştırmaları Ek-4'de verilmiştir.

5.2.2. Yapay Sinir Ağı Modelinin Geliştirilmesi

Yapay sinir ağıyla modelin geliştirilmesinde ThinksPro - Neural Networks for Windows adlı yazılımdan yararlanılmıştır.² Bu yazılım yapay sinir ağı modelleri geliştirilmede çok sayıda mimariyi, öğrenme kuralını ve geçiş fonksiyonunu desteklemesi nedeniyle tercih edilmiştir. Bu yazılımın önemli bir özelliği de eğitim sırasında geliştirilen ağın test verileri üzerindeki performansı ve ağın hatasının eş zamanlı olarak hesaplanarak ekranda grafiksel olarak gösterilmesidir. Bu şekilde ağın verileri ezberleyip ezberlemediği kolaylıkla izlenebilmektedir.

Öncelikle oluşturulacak yapay sinir ağının mimarisi, kullanılacak öğrenme kuralı ve hatanın nasıl hesaplanacağı, girdi ve çıktı katmanındaki neuron sayısı, gizli katman sayısı, katmanlardaki geçiş fonksiyonu ve öğrenme algoritmasına ilişkin öğrenme katsayısı, momentum terimi seçilerek bir yapay sinir ağı modeli oluşturulmuştur.

Yapay sinir ağı modellerinin geliştirilmesinde kullanılacak herhangi bir metodoloji bulunmadığı için, problem alanına uygun modelin bulunması çok sayıda deneme-yanılmayı içeren bir süreç özelliğini gösterir. Uygun modelin geliştirilmesinde kullanılacak mimari ve öğrenme kuralına ilişkin parametreler oluşturulması sezgisel bir yaklaşım gerektirir. Finansal başarısızlığın öngörülmesinde kullanılacak uygun yapay sinir ağı modelinin geliştirilmesi sürecinde de uygun bulunmasına kadar çok sayıda başarısız model geliştirilmiştir. Ancak tüm modellerde yapay sinir ağının ileri beslemeli mimarisi ve geriyayılım kuralı sabit olarak tutulmuştur. Bu çok sayıdaki başarısız modellerin bir kısmında öğrenme gerçekleşmemiş ve

² ThinksPro - Neural Networks for Windows, Special Edition Version 1.00, Copyright © 1991-1995 Logical DesingsConsulting, Inc.

ağdaki hata yüzdesi düşürülemedi. Diğer bir kısım başarısız denemelerde ise ağ verileri ezberlemiş, bu nedenle öğrenme verilerindeki hata oranı düşüş eğilimi, test verilerindeki hata artış ise eğilimi göstermiştir. Bu başarısız modeller elenmiştir. Sonuçta aşağıdaki parametrelere sahip model eğitim verilerini 2722 devirde, %100 oranında öğrenmiştir. Yapay sinir ağının yapısına ilişkin parametreler aşağıdadır (Parametrelere ait çıktı Ek-5'de verilmiştir).

Ağın Mimarisi : İleri Beslemeli çok katmanlı

Hata Hesaplaması : Ortalama Mutlak Hata

| Katmanlara ait parametreler | | | | |
|-----------------------------|---------------|----------------|----------------|-----------------|
| | Giriş Katmanı | Gizli Katman 1 | Gizli Katman 2 | Çıktı |
| Neuron Sayısı | 15 | 1 | 1 | 1 |
| En Fazla Neuron Sayısı | 15 | 5 | 1 | 1 |
| Transfer Fonksiyonu | | Sigmoid (+,-) | Sigmoid | Eşikli doğrusal |
| Öğrenme Oranı | | 0.9 | 0.01 | 0.01 |
| Momentum Katsayısı | | 0.1 | 0 | 0 |

Yapay sinir ağının yapısına ilişkin karar sürecinin başlangıcında, çıktı katmanının eşik değerli bir geçiş fonksiyonuna sahip olması, böylelikle ağın çıkış katmanının sadece 0 ve 1 den oluşan ikili değer üretmesi düşünülmüştür. Ancak bu yapıya sahip bir ağın eğitim verileri çok kısa sürede öğrendiği ve ağın beklenen genellemeye ulaşmadan, eğitim verileri üzerindeki öğrenme sürecini (hatanın sifıra düşmesi nedeniyle) tamamlandığı görülmüştür. Bu sorunun aşılması için çıktı katmanındaki eşik geçiş fonksiyonu eğitim boyunca eşikli-doğrusal geçiş fonksiyonu olarak değiştirilmiştir. Bu değişiklik ağın çıkış katmanındaki hatanın artmasını ve eğitimin uzamasını sağlamıştır. Değişikle ağın daha yüksek bir genellemeye ulaştığı ve test verileri üzerindeki hatasının azaldığı gözlemlenmiştir. Eğitim

sonrasında, ağın çıktı katmanındaki geçiş fonksiyonu tekrar eşikli geçiş fonksiyonuna dönüştürülerek test verilerine ilişkin sonuçlar alındığında, izlenen bu yolun ağın genelleme yeteneğini ve doğru sınıflandırma başarısını arttırdığı sonucuna varılmıştır.³

Yapay sinir ağının örneklem verileri üzerindeki eğitimi hatanın sıfıra düşmesiyle bittiğinde yapay ağın ağırlıkları, yazılım "learning off" durumuna getirilerek sabitlenmiştir. Bu durumda ağ test verileri üzerinde işlem yaparak bunlara ilişkin öngörülerini yapmakta ve işletmeleri gruplara atamaktadır. Ağın test verileri sonu yaptığı atamalar Ek-6'da verilmiştir. Tablodaki "D1" sütunu hedef çıktıyı, bir başka deyişle işletmenin ait olduğu gerçek grubu, "O1" sütunu ise yapay sinir ağının yaptığı atamayı göstermektedir.

5.3.BULGULAR VE DEĞERLENDİRME

Ayırma fonksiyonunun ve yapay sinir ağının örneklem veri kümesine uygulanması sonucu elde edilen öngörü sonuçları aşağıda özetlenmiştir.

Tablo 5. 1 Ayırma analizinin örneklem verileri üzerindeki doğru sınıflandırma başarısı

| GERÇEK GRUP | ÜYE SAYISI | ÖNGÖRÜLEN GRUP ÜYELİĞİ | |
|-------------------|------------|------------------------|-------------------|
| | | Başarısız | Başarısız Olmayan |
| Başarısız | 35 | 27 % 77.1 | 8 % 22.9 |
| Başarısız Olmayan | 35 | 5 % 14.3 | 30 % 85.7 |

Tabloda 35 başarısız işletmenin 27'si (%77.1) ve başarısız olmayan işletmelerin 30'u

³ Test aşamasında ağın çıktı katmanında eşit değer kullanılması, çıktıların 0 ve 1 dışında değer alması durumunda nasıl değerlendirileceğine ilişkin bir kriter olmaması nedeniyle zorunlu olarak tercih edilmiştir.

(% 85.7) si doğru olarak sınıflandırılmıştır. Ancak başarısız işletmelerin 8 tanesi (% 22.9) yanlış öngörüyle başarısız olmayan işletme, başarısız olmayan işletmelerin ise 5 tanesi (%14.3) yanlış öngörüyle başarısız işletme olarak sınıflandırılmıştır. Başarısız işletmeleri, başarısız olmayan olarak sınıflandırma hatası olan Tip I hatası % 22.9; başarısız olmayan işletmeleri, başarısız olarak sınıflandırma hatası olan Tip II hatası ise % 14.3 olarak gerçekleştirmiştir. Buna göre ayırma analizinin modelin geliştirildiği veriler üzerindeki ortalama doğru sınıflandırma başarısı % 81.43 'dir.

Yapay sinir ağının örneklem verileri üzerinde doğru sınıflandırma oranı %100 olarak gerçekleşmiştir. Ancak bu yapay sinir ağının göreceli olarak daha üstün sonuçlar üreteceği şeklinde yorumlanmaması gereken bir sonuçtur. Çünkü yapay sinir ağı doğası gereği eğitim verilerindeki hata sıfırlanıncaya kadar eğitimi sürdürmektedir. Bundan dolayı yapay sinir ağının doğru sınıflandırma oranıyla ayırma fonksiyonunun örneklem verileri üzerinde elde ettiği doğru sınıflandırma oranı karşılaştırılmaması gereken iki sonuçtur. Ayırma fonksiyonu ve yapay sinir ağının doğru sınıflandırma başarıları arasındaki bir karşılaştırma ancak kontrol verileri üzerindeki sonuçlara göre yapılabilecektir.

Örneklem verileri kullanılarak elde edilen ayırma analizi fonksiyonu ve eğitilen yapay sinir ağının, bu veriler dışında ne ölçüde geçerli olduğunun ve hangi modelin daha başarılı olduğunun araştırılması için, daha önce ayrılmış olan 36 işletmeden oluşan kontrol veri kümesi üzerindeki performansları aşağıda özetlenmiştir.

Elde edilen ayırma analizinin 36 birimlik kontrol veri kümesine uygulanması sonucu elde edilen sonuçlar aşağıdadır.

Tablo 5. 2 Ayırma analizinin kontrol verileri üzerindeki başarısı

| GERÇEK GRUP | ÜYE SAYISI | ÖNGÖRÜLEN GRUP ÜYELİĞİ | |
|-------------------|------------|------------------------|-------------------|
| | | Başarısız | Başarısız Olmayan |
| Başarısız | 18 | 16 %88.88 | 2 %11.11 |
| Başarısız Olmayan | 18 | 4 %22.22 | 14 %77.77 |

Tablodan, ayırma analizinin kontrol verilerinde bulunan 18 başarısız işletmenin 16'sını (%88.88) ve başarısız olmayan işletmelerin 14'nü (% 77.77) si doğru olarak sınıflandırdığı görülmektedir. Ancak başarısız işletmelerin 2 tanesi (% 11.11) yanlış öngörüyle başarısız olmayan işletme, başarısız olmayan işletmelerin ise 4 tanesi (% 22.22) yanlış öngörüyle başarısız işletme olarak sınıflandırılmıştır. Başarısız işletmeleri, başarısız olmayan olarak sınıflandırma hatası olan Tip I hatası % 11.11; başarısız olmayan işletmeleri, başarısız olarak sınıflandırma hatası olan Tip II hatası ise % 22.22 olarak gerçekleştirmiştir. Buna göre ayırma analizinin geçerlilik analizi sonucu ortalama doğru sınıflandırma başarısı % 83.33 olmuştur. Bu başarı iyi olarak değerlendirilebilir.

Yapay sinir ağının 36 birimlik veri kümesine uygulanmasıyla elde edilen sonuçlar ise aşağıdaki gibidir.

Tablo 5. 3 Yapay sinir ağının kontrol verileri üzerindeki doğru sınıflandırma başarısı

| GERÇEK GRUP | ÜYE SAYISI | ÖNGÖRÜLEN GRUP ÜYELİĞİ | |
|-------------------|------------|------------------------|-------------------|
| | | Başarısız | Başarısız Olmayan |
| Başarısız | 18 | 17 % 94.44 | 1 % 5.55 |
| Başarısız Olmayan | 18 | 1 % 5.55 | 17 % 94.44 |

Yapay sinir ağının kontrol verilerindeki 18 başarısız işletmenin 17 sini (%94.44) ve 18 başarısız olmayan işletmenin 17 sini (% 94.44) doğru olarak sınıflandırdığı görülmektedir. Ancak yapay sinir ağı yanlış öngörüyle 18 başarısız işletmenin 1 'ini başarısız olmayan olarak ve 18 başarısız olmayan işletmenin de 1 'ini başarısız olarak sınıflandırmıştır. Yapay sinir ağının neden olduğu Tip 1 ve Tip 2 hatasının her ikisi de % 5.55 dir. Bu durumda yapay sinir ağının ortalama doğru sınıflandırma oranı %94.44 olarak gerçekleşmiştir. Bu başarının oldukça iyi olduğu söylenebilir.

Kontrol verilerinde ayırma fonksiyonunun ortalama öngörü başarısı % 83.33 iken, yapay sinir ağının ortalama başarısı % 94.44 olmuştur. Yapay sinir ağı, ayırma fonksiyonuna göre daha başarılı sonuç üretmiştir.

Yapay sinir ağıyla elde edilen sonucun örneklemeden kaynaklanıp kaynaklanmadığının araştırılması için hipotez testi yapılması gerekmektedir.

Hipotezleri burada tekrarlayacak olursak:

$$H_0 : P_{(YSA)} = P_{(AA)}$$

$$H_a : P_{(YSA)} > P_{(AA)}$$

Aşağıda oranların örneklem düzeyinde ortaya çıkan oran farklarının anlamlı olup olmadığı hesaplanmıştır.

Bu test % 5 anlam düzeyinde gerçekleştirilecektir. Bundan dolayı

$$P_{(YSA)} = 2/36 = 0.9444$$

$$P_{(AA)} = 6/36 = 0.8333$$

Yapılan hesaplamalar :

$$\hat{p} = \frac{n_1 P_{(YSA)} + n_2 P_{(AA)}}{n_1 + n_2}$$

$$\hat{p} = \frac{36 \cdot 0.9444 + 0.8333}{36 + 36}$$

$$\hat{p} = \frac{63.9972}{72}$$

$$\hat{p} = 0.8889$$

$$\hat{q} = 1 - \hat{p}$$

$$\hat{q} = 1 - 0.8889$$

$$\hat{q} = 0.1111$$

$$Z_{Hes} = \frac{P_{(YSA)} - P_{(AA)} - (0)}{\sqrt{\hat{p} \cdot \hat{q} \cdot \left(\frac{1}{n_1} + \frac{1}{n_2} \right)}}$$

$$Z_{Hes} = \frac{0.9444 - 0.8333}{\sqrt{0.8889 \cdot 0.1111 \cdot \left[\frac{1}{36} + \frac{1}{36} \right]}}$$

$$Z_{Hes} = \frac{0.1111}{\sqrt{0.0027}} = \frac{0.1111}{0.052}$$

$$Z_{Hes} = 2.1365$$

Yapılan hesaplamalar sonucu $2.1365 > 1.645$ yani $Z_{Hes} > Z_{Tablo}$ olduğu için H_0 hipotezi red edilerek, H_a hipotezi kabul edilmiştir.

Sıfır hipotezinin red edilmesi, yapay sinir ağının doğru sınıflandırma oranının $P_{(YSA)}$, ayırma fonksiyonunun doğru sınıflandırma oranından $P_{(AA)}$ örneklem büyüklüğünde elde edilen üstünlüğün anlamlı olduğu sonucunu desteklemektedir.

Yapay sinir ağının alternatif modelin geliştirilmesi için uygun olup olmadığının araştırılmasında biri ayırma fonksiyonu, diğeri yapay sinir ağıyla iki model geliştirilmiştir. Modellerin finansal başarısızlığı öngörmedeki performansları kontrol verileriyle test edildiğinde, yapay sinir ağı modelinin daha yüksek doğru sınıflandırma oranıyla öngörülerde bulunduğu görülmüştür. Yapay sinir ağı teknolojisinin, finansal başarısızlığın öngörülmesi için kullanılacak modellerin geliştirilmesinde uygun bir araç olduğu sonucuna varılmıştır.

SONUÇ

Finansal başarısızlığın öngörülmesi konusu, işletme ile ilgili tüm çıkar gruplarını yakından ilgilendirmesi nedeniyle, finansal analiz yazınında önemli yer kaplamaktadır. Finansal başarısızlık istenmeyen bir durum olup; finansal başarısızlığın öngörülmesi yöneticiler, yatırımcılar, kredi verenler, devlet, piyasayı düzenleyici kuruluşlar ve bağımsız denetçiler açısından oldukça önem taşır. Finansal başarısızlığın öngörülmesi amacıyla kullanılacak bir model, yöneticilere işletmelerinin geleceği hakkında objektif bilgiler sağlamada, kredi verenlere kredi başvurularının kısa zamanda ve doğrulukla elenmesinde, yatırımcılara değişik risk düzeylerindeki işletmeleri belirleme ve yatırım zamanlamasını yapmada, devlete ise uygun makro ekonomik kararların verilmesinde yardımcı olacağından oldukça önemlidir.

Finansal başarısızlığın öngörülmesinde ilk ortaya çıkan modeller tek değişkenli modellerdir. Ancak tek değişkenli modeller finansal başarısızlığı yalnız bir tek oranı dikkate alarak öngörmeye çalışırlar ve bu durum, ele alınan orana göre bir işletmenin durumunun

değişik şekillerde ve yanlış değerlendirilmesine neden olabilmektedir. Bu olumsuzluk, birden fazla oranı içeren modeller geliştirilmesine olanak veren çok değişkenli matematiksel-istatistiksel tekniklerin kullanılmasıyla ortadan kalkar. Bu çok değişkenli matematiksel -istatistiksel teknikler arasında çok değişkenli ayırma analizi, çoklu regrasyon, Logit, Probit, ayrıca felaket teorisi ve parametrik olmayan teknikler sayılabilir. Ancak çok değişkenli istatistik tekniklerin varsayımlarının çiğnenmesinden ve finansal başarısızlık alanına uygulanmasından kaynaklanan çok sayıda da sorun bulunmaktadır.

Bilgiişlem teknolojisindeki yeni çalışmalar sonucu uygulama alanına giren yapay zeka teknolojisi, finansal başarısızlığın öngörülmesi alanındaki bu sorunların aşılmasına olanak tanıyan bir gelişme olarak karşımıza çıkmaktadır. Bu teknolojilerden ilk ortaya çıkan uzman sistemler ve yapay sinir ağları muhasebe -finans alanında oldukça ilgi uyandıran yapay zeka teknolojileridir.

Yapay sinir ağı; birbiri ile bağlantılı, çok sayıda basit işlem elemanından oluşan bir ağın, biyolojik sinir ağları gibi davranmasıyla oluşturduğu bir bilgiişlem teknolojisidir. Bu bilgiişlem teknolojisi istatistik teknikler gibi varsayımlara gereksinim duymadığı gibi, çok sayıda değişken içeren, karmaşık ve geleneksel yöntemlerle çözülemeyen problem alanlarında, sınıflandırma ve öngörü amacıyla başarılı bir şekilde kullanılabilir.

Yapay sinir ağı sahip olduğu bu avantajlar nedeniyle finansal başarısızlık alanına uygulanmaya elverişli bir araç oluşturmaktadır. Mevcut araştırmalar yapay sinir ağının bu özelliğini desteklemektedir. Bu çalışmada da, finansal başarısızlığın öngörülmesinde yapay sinir ağının, matematiksel - istatistiksel tekniklere karşı bir alternatif araç olarak kullanılıp kullanılmayacağı araştırılmaktadır.

Çalışmada örneklem olarak Sermaye Piyasası Kanunu'na tabi ve/veya İstanbul Menkul Kıymetler Borsası'nda işlem gören, 1983-1997 yılları arasında faaliyet gösteren 106 işletme seçilmiştir. Bu işletmelerin yarısı finansal başarısız, yarısı ise finansal başarısız olmayan işletmelerden oluşmaktadır. Bu işletmelere ait 15 oran hesaplanmıştır. Örneklem 70 işletmeden oluşan deney grubu ve 36 işletmeden oluşan kontrol grubu olmak üzere ikiye ayrılmıştır. Deney grubu örneklem verileri ile biri ayırma analizi tekniğine dayalı , biri yapay sinir ağı ile oluşturulmuş iki model geliştirilmiştir. Elde edilen modellerin, 36 işletmeden oluşan kontrol grubu örneklem verileri üzerinde geçerlilik analizi – testi yapılmıştır.

Geçerlilik analizi sonucu, ayırma analizi modelinin kontrol grubu örneklem verilerini %83,33 oranında doğru sınıflandırdığı görülmüştür. Aynı veriler üzerinde yapay sinir ağının doğru sınıflandırma oranı %94,44 olmuştur.

Örneklem düzeyinde elde edilen sonuçların evren düzeyinde geçerli olup olmadığının test edilmesi için; yapay sinir ağı ile ayırma analizinin doğru sınıflandırma oranlarının eşit olduğu şeklindeki H_0 hipotezi ve yapay sinir ağı ile ayırma analizinin doğru sınıflandırma oranlarının farklı olduğu şeklindeki H_a hipotezi geliştirilmiş ve oranlar arası farkın anlamlı olup olmadığı test edilmiştir. Sonuç olarak %5 anlamlılık düzeyinde (%95 güvenirlilikle) H_0 hipotezi red edilmiş ve oranlar arası fark anlamlı bulunmuştur.

Çalışmada elde edilen bulgular, yapay sinir ağının finansal başarısızlık alanında ayırma analizinden daha yüksek doğru sınıflandırma oranı ile öngörülerde bulunduğunu ortaya koymaktadır. Bu nedenle yöneticiler, kredi verenler, yatırımcılar, devlet ve düzenleyici kuruluşlar, finansal başarısızlığın öngörülmesinde yapay sinir ağı

teknolojilerinden yararlanmaları; kararlarına hız, kolaylık ve doğruluk kazandıracaktır. Yapay sinir ağı modeli tüm bilgi kullanıcıları için finansal başarısızlığı öngörmeye uygun bir araç sunmaktadır ve muhasebe bilgi sisteminin bir parçası olarak ele alınmalıdır.

Finansal başarısızlığın öngörülmesinde yapay sinir ağı teknolojisi kullanılırken; elde edilen modele ilişkin katsayıların ağın içindeki ağırlıklar üzerinde kaldığı ve henüz ağırlıkların yorumlanamadığı, ayrıca yapay sinir ağı modellerinin geliştirilmesinde izlenebilecek belirli bir yöntem olmamasından dolayı, optimal özellikleri taşıyan ağ mimarisinin ancak deneme yanılma yöntemiyle bulunabildiği, göz önünde tutulması gereken konulardır.



KAYNAKLAR

- AHARONY Joseph- JONES Charles P.- SWARY Itzhak, "An Analysis of Risk and Return Characteristics of Corporate Bankruptcy Using Capital Market Data", **The Journal of Finance**, V:XXXV N:4 (September 1980), pp.1001-1016.
- ABDEL-KHALIK A. Rashad - EL-SHESHAI Kamal M., " Information Choice and Utilization in an Experiment on Default Prediction", **Journal of Accounting Research**, V:18 N:2, (Autumn 1980), pp. 325-342.
- AKGÜÇ Öztin, **Finansal Yönetim**, Muhasebe Enstitüsü Yayın No :56, İstanbul, 1989
- AKTAŞ Ramazan, **Endüstri İşletmeleri İçin Finansal Başarısızlık Tahmini - Çok Boyutlu Model Uygulaması**, Türkiye İş Bankası Yay. No:323, Ankara 1993
- ALTMAN Edward I- LORIS Bettina, "A Financial Early Warning system For Over-the-Counter Broker-Dealer", **Journal of Finance**, V.:XXXI, N.:4, (September 1976), pp.1201-1217.
- ALTMAN Edward I. , **The Prediction of Corporate Bankruptcy: A Discriminant Analysis**, Garland Publishing, Inc., New York,1988
- ALTMAN Edward I.- Lorris Bettina, " A Financial Early Warning System for Over-the-Counter Broker-dealers, **The Journal of Finance**, V:XXXI N:4 (September 1976), pp.1201-1217.
- ALTMAN Edward I., "Financial Ratios, Discriminant Analysis and The Prediction of Corporate Bankruptcy", **The Journal of Finance**, V: XXIII, N:4 (September,1968), pp.589-609.
- ALTMAN Edward I., **Corporate Financial Distress and Bankruptcy: A Complete Guide to Predicting and Avoiding Distress and Profiting from Bankruptcy**, Second Ed., John Wiley and Sons, Inc., New York, 1993

- ALTMAN Edward I., EISENBEIS Robert A., "Financial Applications of Discriminant Analysis : A Clarification", **Journal of Financial and Quantative Analysis**, (March 1978), pp.185-188.
- ALTMAN I Altman- MARCO G.- VARETTO F., " Corporate Distress Diagnosis : Comarisons Using Linear Discriminant Analysis and Neural Networks", **Journal of Banking anf Finance**, V:18 (1994), pp.505-529.
- AZIZ Abdül - EMANNUEL Davit C.- LAWSON - Gerald H., "Bankruptcy Prediction - An Investigation at Cash Flow Based Models", **Journal of Management**, V:25 N:5 (September 1988), pp. 419-437
- BARNES Paul, " Methodological Implacations of Non-Normality Distributed Financial Ratios",**Journal of Business Finance & Accounting**, V.:9, N.:1, (1982), pp.51-60.
- BARTOL Kathryn M.-MARTIN Davit C., **Management**, McGraw-Hill Inc., New York,1991
- BAŞBUĞ Ragıp, "Yapay Sinir Ağları", **Byte**, (Şubat 1994), s.167.
- BEAVER William H., "Alternative Accounting Measures As Predictors of Failure", **The Accounting Review**, V:42 N:1 (January 1968), pp.113-122.
- BEAVER William H., "Financial Ratios as Predictors of Failure", Empricial Research in Accounting: Selected Studies,1966, **Journal of Accounting Research**, [1967], pp.71-111.
- BEAVER William H., "Market Prices, Financial Ratios, and the Prediction of Failure", **Journal of Accounting Research**, (Autumn,1968), pp.179-192.
- BISHOP Christopher M., **Neural Netorks for Pattern Recognition**, Clarendon Press, Oxford, 1997
- BOOTH Peter J. ," Decomposition Measures and the Prediction of Financial Failure", **Journal of Business Finance & Accounting**, V.:10 N.:1 (1983), pp.67-82.
- BÜKER Semih, AŞIKOĞLU Rıza, SEVİL Güven, **Finansal Yönetim**, Eskişehir,Ekim 1994,
- CASEY Cornelius - BARTCZAK Norman, " Using Operating Cash Flow Data to Predict Financial Distress: Some Extensions" **Journal of Accounting Research**, V:23 N:1 (Spring 1985), pp.384-401.
- CASEY Cornelius - BARTCZAK Norman, "Cash Flow-It's Not the Bottom Line", **Harvard Business Review**,(July-August1984), pp.60-68.
- CASEY J. Cornelius, "The Usefulness of Accounting Ratios for Subjects' Predictions of Corporate Failure: Replication and Extensions" ,**Journal of Accounting Research**, V:18 N:2,(Autumn 1980), pp.603-613.
- CAUDILL Maureen, "Neural Networks Primer Part III, **AI Expert**, (June,1988), pp.53-59.
- CAUDILL Maureen, "Neural Networks Primer Part I, **AI Expert**, (December,1987),46-52.

- CHEN Kung H.- SHIMERDA Thomas A., "An Empirical Analysis of Useful Financial Ratios", **Financial Management**, (Spring 1981), pp.51-60.
- CICHOCKI Andrzej - UNBEHAVEN Rolf, **Neural Networks for Optimization and signal Processing**, John Wiley and Sons, Gb. Stuttgart, 1993
- COAST K. Pamela-FANT Franklin L, "Recognizing Financial Distress Patterns Using a Neural Network Toll", **Financial Management**, Autumn 1993, pp.142-155.
- DAMBOLENA Ismael G.- KHOURY Sarkis J., "Ratio Stability and Corporate Failure", **The Journal Of Finance**, V:XXXV N:4 (September 1980), pp. 1017-1026.
- De WILDE Philippe, **Neural Network Models**, Second ed., Springer, London, 1997
- DEAKIN Edward B., "Distributions of Financial Accounting Ratios : Some Empirical Evidence", **Accounting Review**, (January 1976), pp. 90-96.
- DEAKIN Edward B., "A Discriminant Analysis of Predictors of Business Failure" **Journal of Accounting Research**, V:10 N:1 (Spring 1972), pp.167-168.
- DOUKAS John, "Bankers Versus Bankruptcy Prediction Models: An Empirical Investigation, 1979-82", **Applied Economics**, V:18 N:7 (1986), pp.479-493.
- EISENBEIS Robert A., "Pitfalls in the Application of Discriminant Analysis in Business, Finance and Economics", **The Journal of Finance** , V.:XXXII N.:3, (June 1977), pp.875-900.
- ELMER Peter J. - BOROWSKI David M., "An Expert System Approach to Financial Analysis: The Case of S&L Bankruptcy", **Financial Management**, (Autumn 1988) , pp.66-75.
- ERDOĞAN Melih- ERDOĞAN Nurten, "Teknolojik Gelişmeler Karşısında Muhasebenin Geleceği", **VI. Ulusal İşletmecilik Kongresi : 2000 li Yıllarda İşletmecilik ve Eğitimi, 12-14 Kasım 1998**, Emel Ofset Matbaacılık ltd. Şti. Antalya,1998, ss. 251-267.
- FOSTER George, **Financial Statement Analysis**, Second Ed. Prentice Hall International Inc., New Jersey, 1986
- GENTRY James A.- NEWBOLD Paul-WHITFORD David T., "Classifying Bankrupt Firms with Fund Flow Components", **Journal of Accounting Research**, V:23 N:1 (Spring 1985), pp.146-160.
- GENTRY James A.- NEWBOLD Paul-WHITFORD David T., "Fund Flow Components, Financial Ratios and Bankruptcy", **Journal of Business Finance and Accounting**, C:14 N4 (Winter 1987), pp.595-605.
- GOONATILAKE Suran - TRELEAVEN Philip, **Intelligent Systems For Finance and Business**, Wiley Chichester,1995

- HAWLEY D. Delvin-JOHNSON John D.- RAINA Dijjotam, "Artificial Neural Systems : A New Tool for Financial Decision-Making", **Financial Analysys Journal**, November-December,1990, pp.63-72.
- HAYKIN Simon, **Neural Networks : A Comprehensive Foundation**, Prentice Hall Int., Inc., New Jersey, 1994
- HECHT-NEILSEN Robert, **Neurocomputing**, Addison-Wesley Pub. Comp., ,Massachusetts, 1989
- HERTZ John- KROGH Anders - PALMER Richard G., **Introduction To The Theory of Neural Computation**, Addison-Wesley Publishing Company ,Redwood City (CA), 1991, p.10
- HING Amy- LAU Ling, "A Five State Financial Distress Prediction Model", **Journal of Accounting Research**, V:25 N:1 (Spring 1987), pp.127-128.
- HINTON Geoffrey E., "Connectionist Learning Procedures", **Artificial Intelligence**, V:40, N:1, p.189.
- HO Thomas - SAUNDERS Anthony, " A Catastrophe Model of Bank Failure", **The Journal of Finance**, V:XXXV, N:5, (December 1980), pp.1189-1207.
- KARELS Gordon V.- PRAKASH,"Multivariate Normality and Forecasting of Business Bankruptcy", **Journal of Business Finance & Accounting**, V.:14, N.:4 (Winter 1987), pp.573-593.
- KASEY Kevin - WATSON Robert, "The Non-submission of Accounts and Small Company Financial Failure Prediction", **Accounting and Business Research**, V:19 N:73 (Winter 1988), pp.47-54.
- KAYAR İsmail, **Anonim Ortaklıkta Mali Durumun Bozulması ve Alınacak Tedbirler**, Mimoza Yay. No: 54, Konya,1997, s.35-36.
- KEASEY K.[Kevin]-WATSON R.[Robert], "Non-financial Symptoms and The Prediction of Small Company Failure: A Test of Argenti's Hypotheses" ,**Journal of Business Finance & Accounting**, V:14 N:3 (Autumn 1987), pp.335-354.
- KETZ, Edward J. "The Effect of General Price-Level Adjustments on the Predictive Ability of Financial Ratios", **Journal of Accounting Research**, V:16 (Supplement 1978), pp.273-284.
- KOHONEN Teuvo, "An Introduction to Neural Computing",**Neural Networks**, V:1 (1988)
- KORN Granino, **A Neural Network Experiments on Personal Computers and Workstations**, A Bradford Book The MIT Press, London,?
- KURTULUŞ Kemal, **Pazarlama Araştırmaları**, Beşinci Baskı, İ.Ü. İşletme Fakültesi Yayın No :28, istanbul, 1996
- LAWRENCE Edward C., "Reporting Delays dor Failed Firms" **Journal of Accounting Research**, V:21 N:2 (Autumn 1983), pp.606-609.

- LIBBY Robert, "Accounting Ratios and the Prediction of Failure: Some Behavioral Evidence", **Journal of Accounting Research**, (Spring 1975), pp.150-161.
- LIBBY R.- TROTMAN K.T. - ZIMMER I., "Member Variation, Recognition of Expertise and Grup Performance", **Journal of Applied Psychology**, (1987), pp.81-87.
- SALCHENBERGER Linda M. - CİNAR E Mine - LASH Nicholas A., " Neural Networks : A New Tool for Predicting Thrift Failures", **Decision Sciences**, V:23, No:4, (July/August,1992),pp.889-916.
- MARCOULIDES George A. – HERSHBERGER Scott L., **Multivaiate statistical Methods : A First Course**, Lawrence erlbaum Associates, Publishers, New Jersey, 1997
- MAWDUDUR Rahman- HALLADAY Maurice, **Accounting Information Systems**, Second Ed., Prentice Hall Inc.,, N:J:,1992.
- MEHRA Pankaj- WAH W. Benjamin, **Artificial Neural Networks : Concepts and Theory**, IEEE Computer Society Press, Washington, 1992, pp.4-5.
- MENSAH Yaw M., " An Examination of Stationary of Multivariate Bankruptcy Prediction Models: A Methodological Study", **Journal of Accounting Research**, V.:22, N.: " (Spring 1984), pp.380-395.;AKTAŞ, A.g.e.,s.78-79.
- MESSIER William F. - HANSEN James V., "Inducing Rules For Expert System Development : An Example Using Default and Bankruptcy Data", **Management Science**, V:34 N:12 (December, 1988) , pp. 1403-1415.
- MEYER Paul A. - PIFER Howar W., "Prediction of Bank Failures", **The Journal of Finance**, C:25 N:? (September 1970), pp.853-858.
- MURPHY C.-CURRIE J.-FAHY M. GOLDEN W., "DSS In Management Accounting", **Management Accounting (London)**, February 1995, pp.37- March 1995
- NORTON Curtis L.-SMITH Ralph E., "A Comparison of Geral Price Level and Historical Cost Financial Statement in Prediction of Bankruptcy", **The Accounting Review**, V.:LIV N.:1 (January 1979), pp.72-87.
- OHLSON James A., "Financial Ratios and Probabilistic Prediction of Bankruptcy", **Journal of Accounting Research**, V:18 N:1 (Spring 1980), pp.109-131.
- RAGHUPATI Williananallur - SCHKADE Lawrence L. - RAJU S. Bapi, " A Neural Network Approach to Bankruptcy Prediction", **Proceedings of the IEEE 24th Annual Hawaii International Conference on Systems Science**, 1991
- RICHARDSON Frederick M.- DAVIDSON Lewis F., " On Linear Discrimination With Accounting Ratios", **Journal of Business Finance & Accounting**, V.:11, N.:4 (Winter 1984), pp.511-525.
- Rick L. WILKSON - Ramesh SHARDA, "Bankruptcy Prediction Using Neural Networks", **Decision Support Systems**, V:11, pp.545-557

- ROJAS Raul, **Neural Networks: A Systematic Introduction**, Springer-Verlag, Berlin, 1996
- RUMELHART D.E.-HINTON G.E.-McCLELLAND, "A General Framework for Parallel Distributed Processing", **Parallel Distributed Processing: Explorations in the Microstructure of Cognition**, Vol: 1, MIT Press Cambridge, Massachusetts, 1986, p.51.
- SCAPENS Robert W. - RYAN Robert J. - FLETCHER Leslie, "Explaining Corporate Failure : A Catastrophe Theory Approach", **Journal of Business Finance & Accounting**, V: 8, N:1, (1981), pp.1-26.
- SCHALKOF Robert J. **Artificial Neural Networks**, The McGraw-Hill Companies, Inc., New York, 1997
- SCHALKOF Robert J., **Pattern Recognition: Statical, Structural and Neural Approaches**, John Wiley & Sons, inc., New York, 1992
- SO Jacky C., " Some Empirical Evidence on the Outliners and non-Normal Distribution of Financial Ratios", **Journal of Business Finance & Accounting**, V.:14, N.:4, (1987), pp483-496.
- TAM Kar Yan- KIANG Melody Y., "Predicting Bank Failures : A Neural Network Approach", **Management Science**, V:38, N:7 (July 1992), pp.926-947.
- TAMARI M., " Les Ratios, Moyen de Prévision des Faillites", **Management International Review**, V.:IV, (1968), pp.22-27.
- TATLI Hüseyin, **Çok Değişkenli İstatistiksel Analiz**, Ankara, 1991.
- TRIGUEIROS Duarte- TAFFLER Richard, " Neural Networks and empirical Research in Accounting", **Accounting and Business Research**, V:26, N:4,(1996), pp.347-355.
- TRIPPI Robert R.- TURBAN Efraim, **Neural Network in Finance and Investing**, Irwin Professional Pub., Chicago, 1996
- TURBAN Efraim, **Decision Support and Expert Systems; Management Support Systems**, Macmillan Publishing Comp., New York, 1993, pp.16;466-472.
- VEMURI V. Rao, **Artificial Neural Networks: Concepts and Control Applications**, IEEE Computer Society Press, Los Alamitos, California, 1992
- WASSERMAN D. Philip-SCHWARTZ Tom , "Neural Networks, Part 2", **IEEE Expert**, Spring 1988, p.10.
- WHITTRED Gred- ZIMMER Ian, "Timeliness of Financial Reporting and Financial Distress", **The Accounting Review**, V:LIX N:2 (April 1984), pp.287-295.
- WIDROW Bernard, LEHR Michael A., "30 Years of Adaptive Neural Networks: Perceptron, Madaline, and Backpropagation", **Proceedings of the IEEE**, V:78, N:9 (September 1990), pp.1417.

WILKINSON Joseph W.- Cerullo Michael J., **Accounting Information Systems; Essential Concepts and Applications**, Third Ed., John Wiley and Sons Inc., New York, 1997

WILSON Nicholas- CHONG Kwee S., " Neural Network Simulation and the Prediction of Corporate Outcomes: Some Empirical Findings", **International Journal of the Economics of Business**, V:2, N:1 (1995), pp. 31-51.

WONG F.S.-P.Z. WANG- GOH T.H.-QUEK B.K., "Fuzzy Neural Systems for Stock Selection", **Financial Analysis Journal**, January-February 1992, pp.47-52.

ZAHEDI Fatma, **Intelligent Systems for Business: Expert Systems with Neural Networks**, Waisworth Publishing Comp., California, 1993.

ZMIJEWSKI Mark E., "Methodological Issues Related to the Estimation of Financial Distress Prediction Models", **Journal of Accounting Research**, V.:22 (Supplement 1984), pp.59-81.

"Report of the Committee on Accounting and Information Systems", **The Accounting Review Supplement**, 1971, pp.289-290.

http://www.dacs.dtic.mil/techs/neural/neural_ToC.html, 15.10.1998

<http://dacs.dtic.mil/tech/neural/neural6.html>

Türk Ticaret Kanunu

İcra İflas Kanunu

Sermaye Piyasası Kanunu

Bankalar Kanunu

TÜM İŞLETMELERİN LİSTESİDİR EK 1/1

168

| <u>No</u> | <u>Adı</u> | <u>YIL</u> | <u>DURUM</u> |
|-----------|-------------------|------------|--------------|
| 1 | EGE GÜBRE SANAYİ | 1990 | 0 |
| 2 | ADANA ÇİMENTO | 1994 | 1 |
| 3 | PETKİM PETRO | 1992 | 0 |
| 4 | AKSA AKRİLİK | 1994 | 1 |
| 5 | PARSAN MAKİNA | 1990 | 0 |
| 6 | AKSU İPLİK | 1992 | 1 |
| 7 | TÜRK HAVA | 1991 | 0 |
| 8 | ANADOLU | 1993 | 1 |
| 9 | SÖKSA-SİNOP | 1990 | 0 |
| 10 | ANADOLU CAM | 1995 | 1 |
| 11 | MARMARIS | 1990 | 0 |
| 12 | BORUSAN | 1992 | 1 |
| 13 | GİMA İHTİYAC | 1991 | 0 |
| 14 | EGE SERAMİK | 1992 | 1 |
| 15 | ABANA | 1991 | 0 |
| 16 | EGE ENDÜSTRİ VE | 1992 | 1 |
| 17 | OKAN TEKSTİL | 1993 | 0 |
| 18 | SÖNMEZ PAMUKLU | 1992 | 1 |
| 19 | METAŞ İZMİR | 1996 | 0 |
| 20 | VIKİNG KAĞIT VE | 1993 | 1 |
| 21 | TÜPRAŞ-TÜRKİYE | 1993 | 0 |
| 22 | TAT KONSERVE | 1992 | 1 |
| 23 | PETROKENT | 1995 | 0 |
| 24 | NETAŞ NORTHERN | 1993 | 1 |
| 25 | EMSAM BEŞYILDIZ | 1994 | 0 |
| 26 | RAKS ELEKTRONİK | 1994 | 1 |
| 27 | TEZSAN TAKİM | 1990 | 0 |
| 28 | PEG PROFILO | 1993 | 1 |
| 29 | PİMAŞ PLASTİK | 1991 | 0 |
| 30 | NET TURİZM | 1997 | 1 |
| 31 | KEPEZ ELEKTRİK | 1993 | 0 |
| 32 | OTOKAR OTOBÜS | 1997 | 1 |
| 33 | PINAR SU SANAYİ | 1996 | 0 |
| 34 | KONYA ÇİMENTO | 1995 | 1 |
| 35 | AKTAŞ ELEKTRİK | 1993 | 0 |
| 36 | PETROL OFİSİ A.Ş. | 1994 | 1 |
| 37 | MAKİNA TAKİM | 1991 | 0 |
| 38 | SASA SUN'İ VE | 1996 | 1 |
| 39 | POLYLEN | 1990 | 0 |

TÜM İŞLETMELERİN LİSTESİDİR EK 1/2

169

| <u>No</u> | <u>Adı</u> | <u>YIL</u> | <u>DURUM</u> |
|-----------|-------------------|------------|--------------|
| 40 | MEGES BOYA | 1997 | 1 |
| 41 | AFYON ÇİMENTO | 1994 | 0 |
| 42 | TURK YTONG | 1988 | 1 |
| 43 | EMSAN | 1994 | 0 |
| 44 | KUMAŞ KÜTAHYA | 1987 | 1 |
| 45 | ENTDEMİR | 1987 | 0 |
| 46 | TOROS GÜBRE VE | 1988 | 1 |
| 47 | ASIL ÇELİK SANAYİ | 1984 | 0 |
| 48 | MİGROS TÜRK | 1992 | 1 |
| 49 | BMC SANAYİ VE | 1987 | 0 |
| 50 | SARKUYSAN | 1992 | 1 |
| 51 | BUTRAK BURDUR | 1984 | 0 |
| 52 | MERKO GIDA | 1994 | 1 |
| 53 | ÇAMSAN AĞAÇ VE | 1984 | 0 |
| 54 | KASTAMONU | 1988 | 1 |
| 55 | ÇİHANKUR İNŞAAT | 1985 | 0 |
| 56 | MODERN KARTON | 1988 | 1 |
| 57 | ÇİNKUR ÇİNKO | 1985 | 0 |
| 58 | BAGFAŞ BANDIRMA | 1992 | 1 |
| 59 | DOKUSAN | 1985 | 0 |
| 60 | BRISA | 1992 | 1 |
| 61 | GÖNEN GIDA | 1987 | 0 |
| 62 | EGE PROFİL | 1993 | 1 |
| 63 | GÜBRE | 1986 | 0 |
| 64 | BANVIT BANDIRMA | 1995 | 1 |
| 65 | KARADENİZ BAKIR | 1984 | 0 |
| 66 | ÇUMRA KAĞIT | 1993 | 1 |
| 67 | KEMSAN KAYSERİ | 1985 | 0 |
| 68 | ALTINYILDIZ | 1987 | 1 |
| 69 | LÜKS KADİFE | 1984 | 0 |
| 70 | ARÇELİK A.Ş. | 1985 | 1 |
| 71 | MEYBUZ MEYVE VE | 1984 | 0 |
| 72 | ÇANAKKALE | 1987 | 1 |
| 73 | OTOSAN | 1985 | 0 |
| 74 | ÇELİK HALAT VE | 1985 | 1 |
| 75 | PANCAR MOTOR | 1985 | 0 |
| 76 | DÖKTAŞ | 1986 | 1 |
| 77 | PİMAŞ PLASTİK | 1984 | 0 |
| 78 | ECZACIBAŞI YAPI | 1986 | 1 |

TÜM İŞLETMELERİN LİSTESİDİR EK 1/3

170

| <u>No</u> | <u>Adı</u> | <u>YIL</u> | <u>DURUM</u> |
|-----------|---------------------|------------|--------------|
| 79 | PINAR ENTEGRE | 1985 | 0 |
| 80 | DITAŞ DOĞAN | 1986 | 1 |
| 81 | SİSTAŞ SIIRT | 1986 | 0 |
| 82 | GESAŞ GENEL | 1987 | 1 |
| 83 | SUMAŞ SUN'I | 1986 | 0 |
| 84 | İE KİMYA EVİ T.A.Ş. | 1985 | 1 |
| 85 | TERME METAL | 1985 | 0 |
| 86 | KENT GIDA | 1985 | 1 |
| 87 | TUNGAŞ TUNCELLI | 1986 | 0 |
| 88 | KAV ORMAN | 1985 | 1 |
| 89 | TÜRK TUBORG | 1985 | 0 |
| 90 | MODERN KARTON | 1985 | 1 |
| 91 | TURKTUR GIDA | 1985 | 0 |
| 92 | AKKARDAN SANAYİ | 1984 | 1 |
| 93 | UŞAK SERAMİK | 1983 | 0 |
| 94 | BOTAŞ BORNOVA | 1984 | 1 |
| 95 | ALTINYUNUS | 1990 | 0 |
| 96 | ERCIYAS BİRACILIK | 1985 | 1 |
| 97 | HÜRRIYET | 1993 | 0 |
| 98 | DENTAŞ OLUKLU | 1984 | 1 |
| 99 | BİRLİK MENSUCAT | 1996 | 0 |
| 100 | DENİZLİ BASMA VE | 1983 | 1 |
| 101 | DENİZLİ CAM | 1990 | 0 |
| 102 | FENİŞ ALÜMİNYUM | 1992 | 1 |
| 103 | DOĞUSAN BORU | 1993 | 0 |
| 104 | ALARKO SANAYİ | 1993 | 1 |
| 105 | DURAN OFSET | 1991 | 0 |
| 106 | HAZNEDAR ATEŞ | 1995 | 1 |

EX 2/2

TEST - GEÇERLİLİK ANALİZİ VERİLERİ

| X1 | X2 | X3 | X4 | X5 | X6 | X7 | X8 | X9 | X10 | X11 | X12 | X13 | X14 | X15 | DURUM |
|-----|-------------------|--------------------|--------------------|--------------------|-------------------|--------------------|--------------------|-------------------|-------------------|-------------------|--------------------|---------------------|---------------------|---------------------|--------------------|
| 71 | 1.482416306869410 | 0.67165960334384 | 1.020432184839170 | 1.812332791259480 | 0.644489148390159 | 0.022881940338626 | 13.881307158104100 | 0.1287571919493 | 0.255350503369509 | 0.628772462184043 | 0.232529145229788 | -0.053397240696298 | -0.228808948245202 | -0.1716551031502520 | -0.456547556529288 |
| 72 | 3.950260702832030 | 0.5923295707080 | 0.293487574887301 | 0.374511767597178 | 0.272427066516345 | 6.625874551552360 | 1.942567462060750 | 3.888089420529300 | 1.300335488532300 | 3.720866316260779 | 0.372086631626079 | 0.293487574887301 | 0.374511767597178 | 0.272427066516345 | 0.293487574887301 |
| 73 | 3.950260702832030 | 0.5923295707080 | 0.293487574887301 | 0.374511767597178 | 0.272427066516345 | 6.625874551552360 | 1.942567462060750 | 3.888089420529300 | 1.300335488532300 | 3.720866316260779 | 0.372086631626079 | 0.293487574887301 | 0.374511767597178 | 0.272427066516345 | 0.293487574887301 |
| 74 | 3.723559791689980 | 2.319521161062080 | 1.177009040060304 | 0.290598218412980 | 0.225166519578107 | 21.161231594110100 | 33.577474027290400 | 2.232831682248710 | 3.089195873737180 | 1.537100089833800 | 1.909883189428500 | 0.353890544588000 | 0.301864947433428 | 0.298926236834388 | 0.4559486916541571 |
| 75 | 1.880722718303910 | 0.388757915242005 | 1.448449424940300 | 1.591641729195180 | 0.609625254693439 | 0.673541188140870 | 18.576628293455500 | 1.084584802788800 | 3.081055897630400 | 2.443300208948300 | 0.853833933885702 | 0.691772238218200 | 0.239423714437788 | 0.095526226242390 | 0.01507719565657 |
| 76 | 1.880722718303910 | 0.388757915242005 | 1.448449424940300 | 1.591641729195180 | 0.609625254693439 | 0.673541188140870 | 18.576628293455500 | 1.084584802788800 | 3.081055897630400 | 2.443300208948300 | 0.853833933885702 | 0.691772238218200 | 0.239423714437788 | 0.095526226242390 | 0.01507719565657 |
| 77 | 1.880722718303910 | 0.388757915242005 | 1.448449424940300 | 1.591641729195180 | 0.609625254693439 | 0.673541188140870 | 18.576628293455500 | 1.084584802788800 | 3.081055897630400 | 2.443300208948300 | 0.853833933885702 | 0.691772238218200 | 0.239423714437788 | 0.095526226242390 | 0.01507719565657 |
| 78 | 1.880722718303910 | 0.388757915242005 | 1.448449424940300 | 1.591641729195180 | 0.609625254693439 | 0.673541188140870 | 18.576628293455500 | 1.084584802788800 | 3.081055897630400 | 2.443300208948300 | 0.853833933885702 | 0.691772238218200 | 0.239423714437788 | 0.095526226242390 | 0.01507719565657 |
| 79 | 1.880722718303910 | 0.388757915242005 | 1.448449424940300 | 1.591641729195180 | 0.609625254693439 | 0.673541188140870 | 18.576628293455500 | 1.084584802788800 | 3.081055897630400 | 2.443300208948300 | 0.853833933885702 | 0.691772238218200 | 0.239423714437788 | 0.095526226242390 | 0.01507719565657 |
| 80 | 1.880722718303910 | 0.388757915242005 | 1.448449424940300 | 1.591641729195180 | 0.609625254693439 | 0.673541188140870 | 18.576628293455500 | 1.084584802788800 | 3.081055897630400 | 2.443300208948300 | 0.853833933885702 | 0.691772238218200 | 0.239423714437788 | 0.095526226242390 | 0.01507719565657 |
| 81 | 1.880722718303910 | 0.388757915242005 | 1.448449424940300 | 1.591641729195180 | 0.609625254693439 | 0.673541188140870 | 18.576628293455500 | 1.084584802788800 | 3.081055897630400 | 2.443300208948300 | 0.853833933885702 | 0.691772238218200 | 0.239423714437788 | 0.095526226242390 | 0.01507719565657 |
| 82 | 1.880722718303910 | 0.388757915242005 | 1.448449424940300 | 1.591641729195180 | 0.609625254693439 | 0.673541188140870 | 18.576628293455500 | 1.084584802788800 | 3.081055897630400 | 2.443300208948300 | 0.853833933885702 | 0.691772238218200 | 0.239423714437788 | 0.095526226242390 | 0.01507719565657 |
| 83 | 0.853917229122388 | 0.298123350038921 | 0.620561866028122 | 0.693121433082200 | 0.78551570988708 | 28.591202210882700 | 8.875893198767530 | 2.873847478338200 | 4.542410835876900 | 3.204228110548970 | 8.891811281824400 | 0.101469238587520 | 0.421346703038190 | 0.434138893781864 | 0.5815241180034 |
| 84 | 3.281185915115878 | 0.198079192182401 | 0.988073924427061 | 0.3344728611781710 | 0.789596078721515 | -0.005477004889572 | 25.10801812983800 | 2.824128174744810 | 5.822126409088730 | 1.671685704173080 | 2.100178878917880 | 0.41887172653817488 | 0.1321789203085194 | 0.13128515817910 | 0.582521136237800 |
| 85 | 1.942849175394645 | 0.938076020063040 | 1.223722891891670 | 2.021611359548500 | 0.687710930347824 | 1.880005278074800 | 32.1854827891830 | 2.231854827891830 | 6.03360733635720 | 0.017604057119871 | 0.0086333794262450 | -0.029232730404000 | -0.0304511725488110 | -0.3389482628672270 | 0.1268718853665891 |
| 86 | 2.779262842214070 | 0.020271714503130 | 0.117270287638588 | 0.970563279884800 | 0.492515962378911 | 4.288876078482780 | 3.147120418848170 | 0.038874500490571 | 0.011032870037177 | 0.307889387888600 | 1.194130228243300 | 0.5232835948188021 | 0.487276821218489 | 0.451402525262526 | 0.580292894650931 |
| 87 | 15.97051334494400 | 10.890317562848900 | 0.091023746890344 | 0.188182026282922 | 0.143976532315784 | -0.18778218075681 | 8.668386737852110 | 0.780181780862242 | 0.142788878788828 | 0.277326781038322 | 0.135286373181765 | 0.6001574848888448 | -0.052855474080583 | -0.138118006888074 | 0.038203288184853 |
| 88 | 5.40806947303180 | 6.797007289483080 | 0.05285547303180 | 0.073807350387235 | 0.08802649071418 | 28.800973400673400 | 28.891741280298400 | 2.418897786897080 | 0.180780589903015 | 1.179840596940440 | 0.241800073372253 | -0.628548900441510 | -1.343484804004280 | -1.362788354239740 | -1.625358436737570 |
| 89 | 3.40426435974410 | 0.122384879461611 | 2.248280378223880 | 3.027335073949740 | 0.783882786759881 | 0.87172928914657 | 0.854512883892800 | 1.748410242453930 | 0.886294969402450 | 0.02975892827206 | 0.073804122813043 | 0.022803265340912 | -2.894884311889800 | -3.423851020647320 | -0.102164232831642 |
| 90 | 1.6888688354611 | 0.02984879461611 | 0.02984879461611 | 0.02984879461611 | 0.02984879461611 | 0.02984879461611 | 0.02984879461611 | 0.02984879461611 | 0.02984879461611 | 0.02984879461611 | 0.02984879461611 | 0.02984879461611 | 0.02984879461611 | 0.02984879461611 | 0.02984879461611 |
| 91 | 1.6888688354611 | 0.02984879461611 | 0.02984879461611 | 0.02984879461611 | 0.02984879461611 | 0.02984879461611 | 0.02984879461611 | 0.02984879461611 | 0.02984879461611 | 0.02984879461611 | 0.02984879461611 | 0.02984879461611 | 0.02984879461611 | 0.02984879461611 | 0.02984879461611 |
| 92 | 1.6888688354611 | 0.02984879461611 | 0.02984879461611 | 0.02984879461611 | 0.02984879461611 | 0.02984879461611 | 0.02984879461611 | 0.02984879461611 | 0.02984879461611 | 0.02984879461611 | 0.02984879461611 | 0.02984879461611 | 0.02984879461611 | 0.02984879461611 | 0.02984879461611 |
| 93 | 1.6888688354611 | 0.02984879461611 | 0.02984879461611 | 0.02984879461611 | 0.02984879461611 | 0.02984879461611 | 0.02984879461611 | 0.02984879461611 | 0.02984879461611 | 0.02984879461611 | 0.02984879461611 | 0.02984879461611 | 0.02984879461611 | 0.02984879461611 | 0.02984879461611 |
| 94 | 1.6888688354611 | 0.02984879461611 | 0.02984879461611 | 0.02984879461611 | 0.02984879461611 | 0.02984879461611 | 0.02984879461611 | 0.02984879461611 | 0.02984879461611 | 0.02984879461611 | 0.02984879461611 | 0.02984879461611 | 0.02984879461611 | 0.02984879461611 | 0.02984879461611 |
| 95 | 1.6888688354611 | 0.02984879461611 | 0.02984879461611 | 0.02984879461611 | 0.02984879461611 | 0.02984879461611 | 0.02984879461611 | 0.02984879461611 | 0.02984879461611 | 0.02984879461611 | 0.02984879461611 | 0.02984879461611 | 0.02984879461611 | 0.02984879461611 | 0.02984879461611 |
| 96 | 1.6888688354611 | 0.02984879461611 | 0.02984879461611 | 0.02984879461611 | 0.02984879461611 | 0.02984879461611 | 0.02984879461611 | 0.02984879461611 | 0.02984879461611 | 0.02984879461611 | 0.02984879461611 | 0.02984879461611 | 0.02984879461611 | 0.02984879461611 | 0.02984879461611 |
| 97 | 1.6888688354611 | 0.02984879461611 | 0.02984879461611 | 0.02984879461611 | 0.02984879461611 | 0.02984879461611 | 0.02984879461611 | 0.02984879461611 | 0.02984879461611 | 0.02984879461611 | 0.02984879461611 | 0.02984879461611 | 0.02984879461611 | 0.02984879461611 | 0.02984879461611 |
| 98 | 1.6888688354611 | 0.02984879461611 | 0.02984879461611 | 0.02984879461611 | 0.02984879461611 | 0.02984879461611 | 0.02984879461611 | 0.02984879461611 | 0.02984879461611 | 0.02984879461611 | 0.02984879461611 | 0.02984879461611 | 0.02984879461611 | 0.02984879461611 | 0.02984879461611 |
| 99 | 1.6888688354611 | 0.02984879461611 | 0.02984879461611 | 0.02984879461611 | 0.02984879461611 | 0.02984879461611 | 0.02984879461611 | 0.02984879461611 | 0.02984879461611 | 0.02984879461611 | 0.02984879461611 | 0.02984879461611 | 0.02984879461611 | 0.02984879461611 | 0.02984879461611 |
| 100 | 1.6888688354611 | 0.02984879461611 | 0.02984879461611 | 0.02984879461611 | 0.02984879461611 | 0.02984879461611 | 0.02984879461611 | 0.02984879461611 | 0.02984879461611 | 0.02984879461611 | 0.02984879461611 | 0.02984879461611 | 0.02984879461611 | 0.02984879461611 | 0.02984879461611 |
| 101 | 1.6888688354611 | 0.02984879461611 | 0.02984879461611 | 0.02984879461611 | 0.02984879461611 | 0.02984879461611 | 0.02984879461611 | 0.02984879461611 | 0.02984879461611 | 0.02984879461611 | 0.02984879461611 | 0.02984879461611 | 0.02984879461611 | 0.02984879461611 | 0.02984879461611 |
| 102 | 1.6888688354611 | 0.02984879461611 | 0.02984879461611 | 0.02984879461611 | 0.02984879461611 | 0.02984879461611 | 0.02984879461611 | 0.02984879461611 | 0.02984879461611 | 0.02984879461611 | 0.02984879461611 | 0.02984879461611 | 0.02984879461611 | 0.02984879461611 | 0.02984879461611 |
| 103 | 1.6888688354611 | 0.02984879461611 | 0.02984879461611 | 0.02984879461611 | 0.02984879461611 | 0.02984879461611 | 0.02984879461611 | 0.02984879461611 | 0.02984879461611 | 0.02984879461611 | 0.02984879461611 | 0.02984879461611 | 0.02984879461611 | 0.02984879461611 | 0.02984879461611 |
| 104 | 1.6888688354611 | 0.02984879461611 | 0.02984879461611 | 0.02984879461611 | 0.02984879461611 | 0.02984879461611 | 0.02984879461611 | 0.02984879461611 | 0.02984879461611 | 0.02984879461611 | 0.02984879461611 | 0.02984879461611 | 0.02984879461611 | 0.02984879461611 | 0.02984879461611 |
| 105 | 1.6888688354611 | 0.02984879461611 | 0.02984879461611</ | | | | | | | | | | | | |

----- D I S C R I M I N A N T A N A L Y S I S -----

On groups defined by Y

70 (Unweighted) cases were processed.
 0 of these were excluded from the analysis.
 70 (Unweighted) cases will be used in the analysis.

Number of cases by group

| Y | Number of cases | | Label |
|-------|-----------------|----------|-------|
| | Unweighted | Weighted | |
| 0 | 35 | 35.0 | |
| 1 | 35 | 35.0 | |
| Total | 70 | 70.0 | |

Group means

| Y | X10 | X11 | X12 | X13 |
|-------|---------|---------|--------|--------|
| 0 | 4.96188 | .91681 | .16248 | .01049 |
| 1 | 3.57428 | 1.60780 | .32879 | .21335 |
| Total | 4.26808 | 1.26231 | .24564 | .11192 |

| Y | X14 | X15 | X2 | X3 |
|-------|---------|---------|---------|---------|
| 0 | -.10937 | -.06303 | .67755 | 2.67943 |
| 1 | .16767 | .44432 | 1.69820 | .88357 |
| Total | .02915 | .19065 | 1.18787 | 1.78150 |

| Y | X4 | X5 | X6 | X7 |
|-------|---------|--------|-----------|-----------|
| 0 | 3.67748 | .65915 | .16876 | 117.81160 |
| 1 | 1.15309 | .48476 | 785.02955 | 165.58403 |
| Total | 2.41529 | .57196 | 392.59915 | 141.69782 |

| Y | X8 | X9 | X1 |
|-------|---------|---------|---------|
| 0 | 2.40459 | 6.60222 | 1.13137 |
| 1 | 2.37029 | 9.23380 | 2.31503 |
| Total | 2.38744 | 7.91801 | 1.72320 |

Group standard deviations

| Y | X10 | X11 | X12 | X13 |
|-------|---------|---------|--------|--------|
| 0 | 6.43006 | .61287 | .24687 | .24426 |
| 1 | 3.02922 | 1.24227 | .11475 | .13119 |
| Total | 5.03817 | 1.03277 | .20865 | .21981 |

| Y | X14 | X15 | X2 | X3 |
|-------|--------|--------|---------|---------|
| 0 | .31497 | .44167 | .32451 | 2.86742 |
| 1 | .11426 | .29949 | 1.74544 | .66717 |
| Total | .27347 | .45343 | 1.34808 | 2.25583 |

| Y | X4 | X5 | X6 | X7 |
|-------|---------|--------|------------|-----------|
| 0 | 3.64568 | .22573 | 4.07307 | 183.80829 |
| 1 | .77322 | .15667 | 4080.37669 | 504.59814 |
| Total | 2.90861 | .21193 | 2891.42358 | 377.74504 |

| Y | X8 | X9 | X1 |
|-------|---------|----------|---------|
| 0 | 1.90639 | 16.51844 | .57021 |
| 1 | 1.33852 | 15.12748 | 2.00526 |
| Total | 1.63522 | 15.77880 | 1.58017 |

Pooled within-groups covariance matrix with 68 degrees of freedom

| | X10 | X11 | X12 | X13 |
|-----|-----------|----------------|----------------|---------------|
| X10 | 25.2610 | | | |
| X11 | 3.0971 | .9594 | | |
| X12 | -.0405 | -.0284 | .0371 | |
| X13 | .0627 | -7.2269776E-03 | .0234 | .0384 |
| X14 | .1671 | .0181 | .0188 | .0342 |
| X15 | .4526 | .1321 | .0160 | .0282 |
| X2 | -.4339 | -.1220 | .0426 | .0575 |
| X3 | 8.0733 | .4145 | .0291 | .0839 |
| X4 | 9.8732 | .4046 | 1.2522669E-03 | .0632 |
| X5 | .5190 | .0382 | -6.1436356E-03 | 4.5019867E-03 |
| X6 | 3917.1906 | 2167.0610 | -87.5936 | -50.9320 |
| X7 | -52.9860 | -27.0114 | 1.5745 | 18.6265 |
| X8 | 1.4938 | .7953 | .0376 | -.0943 |
| X9 | 60.2820 | 11.6586 | -.4132 | -.0243 |
| X1 | -.8480 | -.1436 | .0478 | .0637 |

| | X14 | X15 | X2 | X3 |
|-----|---------------|---------------|----------|----------|
| X14 | .0561 | | | |
| X15 | .0528 | .1424 | | |
| X2 | .0835 | .0477 | 1.5759 | |
| X3 | .0404 | -.1047 | -.2457 | 4.3336 |
| X4 | .0348 | -.1466 | -.2170 | 5.2963 |
| X5 | 4.2863246E-04 | 1.5077407E-03 | -.0448 | .2768 |
| X6 | -27.2079 | 192.9815 | 30.7126 | -59.0835 |
| X7 | -10.1112 | 22.3442 | -43.5883 | 47.4179 |
| X8 | -.0773 | .0876 | -.2078 | -.5826 |
| X9 | .2431 | 2.7517 | -.4381 | 11.3807 |
| X1 | .0988 | .0410 | 1.7835 | -.5141 |

| | X4 | X5 | X6 | X7 |
|----|-----------|---------|--------------|-------------|
| X4 | 6.9444 | | | |
| X5 | .3622 | .0377 | | |
| X6 | -113.3396 | -8.5904 | 8324745.2800 | |
| X7 | 29.5754 | 13.0631 | -53759.2592 | 144202.3857 |
| X8 | -.6954 | -.0940 | 2147.0881 | -59.6763 |
| X9 | 14.4372 | .7595 | 28488.2387 | 394.1721 |
| X1 | -.5449 | -.0761 | -3.0501 | -70.1780 |

| | X8 | X9 | X1 |
|----|--------|----------|--------|
| X8 | 2.7130 | | |
| X9 | 8.7641 | 250.8498 | |
| X1 | -.2390 | -1.2720 | 2.1731 |

Pooled within-groups correlation matrix ✓

| | X10 | X11 | X12 | X13 | X14 | X15 |
|-----|---------|---------|---------|---------|---------|---------|
| X10 | 1.00000 | | | | | |
| X11 | .62911 | 1.00000 | | | | |
| X12 | -.04191 | -.15038 | 1.00000 | | | |
| X13 | .06360 | -.03763 | .61873 | 1.00000 | | |
| X14 | .14034 | .07808 | .41271 | .73583 | 1.00000 | |
| X15 | .23864 | .35736 | .22071 | .38182 | .59112 | 1.00000 |
| X2 | -.06876 | -.09925 | .17622 | .23362 | .28084 | .10080 |
| X3 | .77161 | .20327 | .07264 | .20558 | .08194 | -.13335 |
| X4 | .74544 | .15674 | .00247 | .12238 | .05576 | -.14747 |
| X5 | .53143 | .20057 | -.16426 | .11819 | .00931 | .02057 |
| X6 | .27012 | .76680 | -.15771 | -.09004 | -.03980 | .17726 |
| X7 | -.02776 | -.07262 | .02154 | .25019 | -.11239 | .15594 |
| X8 | .18045 | .49297 | .11853 | -.29207 | -.19806 | .14102 |
| X9 | .75728 | .75151 | -.13554 | -.00782 | .06479 | .46044 |
| X1 | -.11445 | -.09947 | .16839 | .22025 | .28285 | .07368 |

| | X2 | X3 | X4 | X5 | X6 | X7 |
|----|---------|---------|---------|---------|---------|---------|
| X2 | 1.00000 | | | | | |
| X3 | -.09402 | 1.00000 | | | | |
| X4 | -.06558 | .96546 | 1.00000 | | | |
| X5 | -.18368 | .68424 | .70739 | 1.00000 | | |
| X6 | .00848 | -.00984 | -.01491 | -.01532 | 1.00000 | |
| X7 | -.09144 | .05998 | .02955 | .17705 | -.04907 | 1.00000 |
| X8 | -.10052 | -.16991 | -.16022 | -.29377 | .45180 | -.09541 |
| X9 | -.02204 | .34517 | .34591 | .24680 | .62341 | .06554 |
| X1 | .96377 | -.16752 | -.14027 | -.26576 | -.00072 | -.12536 |

| | X8 | X9 | X1 |
|----|---------|---------|---------|
| X8 | 1.00000 | | |
| X9 | .33595 | 1.00000 | |
| X1 | -.09842 | -.05448 | 1.00000 |

Covariance matrix for group 0,

| | X10 | X11 | X12 | X13 |
|-----|-----------|----------|---------|---------|
| X10 | 41.3457 | | | |
| X11 | 2.8732 | .3756 | | |
| X12 | .1206 | .0250 | .0609 | |
| X13 | .2863 | .0507 | .0365 | .0597 |
| X14 | .4938 | .0849 | .0298 | .0588 |
| X15 | .5788 | .1093 | .0283 | .0393 |
| X2 | .3331 | .0752 | .0246 | .0409 |
| X3 | 15.0067 | .6734 | .0821 | .1730 |
| X4 | 18.5307 | .6933 | .0253 | .1324 |
| X5 | .7972 | .0423 | -.0074 | .0108 |
| X6 | 3.8132 | .8906 | .5247 | .7210 |
| X7 | -185.9744 | -12.6151 | -7.7574 | -6.6383 |
| X8 | -.3898 | .0128 | .1662 | -.1074 |
| X9 | 83.6682 | 5.7761 | -.0196 | .3278 |
| X1 | -.1295 | .1077 | .0252 | .0493 |

| | X14 | X15 | X2 | X3 |
|-----|----------|----------|----------|----------|
| X14 | .0992 | | | |
| X15 | .0906 | .1951 | | |
| X2 | .0567 | .0845 | .1053 | |
| X3 | .1136 | -.2411 | -.0503 | 8.2221 |
| X4 | .1090 | -.3112 | -.0418 | 10.1048 |
| X5 | .0093 | -.0038 | .0053 | .4648 |
| X6 | .7518 | .4561 | .4881 | .9638 |
| X7 | -27.1028 | -23.8644 | -18.3667 | -49.5820 |
| X8 | -.0966 | .0389 | -.0102 | -1.2624 |
| X9 | .8926 | 3.5361 | 1.3307 | 20.8782 |
| X1 | .0769 | .1008 | .1214 | -.4238 |

| | X4 | X5 | X6 | X7 |
|----|----------|--------|---------|------------|
| X4 | 13.2910 | | | |
| X5 | .6118 | .0510 | | |
| X6 | -.0451 | -.0318 | 16.5899 | |
| X7 | -84.8149 | 1.5633 | -4.8975 | 33785.4861 |
| X8 | -1.4861 | -.2222 | 1.4820 | -18.2293 |
| X9 | 27.5096 | 1.1604 | 3.8766 | -306.5667 |
| X1 | -.5326 | -.0209 | .5590 | -25.7548 |

| | X8 | X9 | X1 |
|----|--------|----------|-------|
| X8 | 3.6343 | | |
| X9 | .5613 | 272.8589 | |
| X1 | -.0047 | .4691 | .3251 |

Covariance matrix for group 1,

| | X10 | X11 | X12 | X13 |
|-----|-----------|-----------|-----------|-----------|
| X10 | 9.1762 | | | |
| X11 | 3.3210 | 1.5432 | | |
| X12 | -.2017 | -.0817 | .0132 | |
| X13 | -.1610 | -.0652 | .0102 | .0172 |
| X14 | -.1596 | -.0486 | .0078 | .0095 |
| X15 | .3263 | .1549 | .0037 | .0172 |
| X2 | -1.2008 | -.3193 | .0606 | .0741 |
| X3 | 1.1398 | .1555 | -.0239 | -.0052 |
| X4 | 1.2157 | .1158 | -.0228 | -.0060 |
| X5 | .2407 | .0340 | -.0049 | -.0018 |
| X6 | 7830.5680 | 4333.2314 | -175.7120 | -102.5851 |
| X7 | 80.0024 | -41.4077 | 10.9063 | 43.8913 |
| X8 | 3.3775 | 1.5779 | -.0910 | -.0813 |
| X9 | 36.8958 | 17.5410 | -.8069 | -.3764 |
| X1 | -1.5664 | -.3949 | .0704 | .0780 |

| | X14 | X15 | X2 | X3 |
|-----|----------|----------|----------|-----------|
| X14 | .0131 | | | |
| X15 | .0151 | .0897 | | |
| X2 | .1104 | .0110 | 3.0466 | |
| X3 | -.0328 | .0316 | -.4411 | .4451 |
| X4 | -.0393 | .0180 | -.3921 | .4879 |
| X5 | -.0085 | .0068 | -.0949 | .0887 |
| X6 | -55.1677 | 385.5070 | 60.9372 | -119.1308 |
| X7 | 6.8804 | 68.5529 | -68.8099 | 144.4177 |
| X8 | -.0580 | .1364 | -.4055 | .0972 |
| X9 | -.4064 | 1.9674 | -2.2070 | 1.8832 |
| X1 | .1206 | -.0189 | 3.4457 | -.6043 |

| | X4 | X5 | X6 | X7 |
|----|-----------|----------|---------------|-------------|
| X4 | .5979 | | | |
| X5 | .1126 | .0245 | | |
| X6 | -226.6340 | -17.1490 | 16649473.9702 | |
| X7 | 143.9658 | 24.5630 | -107513.6209 | 254619.2854 |
| X8 | .0952 | .0342 | 4292.6942 | -101.1233 |

| | X4 | X5 | X6 | X7 |
|----|---------|----------|------------|-----------|
| X9 | 1.3648 | .3585 | 56972.6008 | 1094.9110 |
| X1 | -.5572 | -.1314 | -6.6592 | -114.6012 |
| | X8 | X9 | X1 | |
| X8 | 1.7916 | | | |
| X9 | 16.9669 | 228.8407 | | |
| X1 | -.4732 | -3.0131 | 4.0211 | |

Total covariance matrix with 69 degrees of freedom

| | X10 | X11 | X12 | X13 |
|-----|-----------|-----------|----------|-----------|
| X10 | 25.3832 | | | |
| X11 | 2.8090 | 1.0666 | | |
| X12 | -.0985 | .0012 | .0435 | |
| X13 | -.0096 | .0284 | .0316 | .0483 |
| X14 | .0672 | .0664 | .0302 | .0479 |
| X15 | .2675 | .2191 | .0372 | .0539 |
| X2 | -.7868 | .0586 | .0850 | .1092 |
| X3 | 8.5883 | .0937 | -.0471 | -.0097 |
| X4 | 10.6185 | -.0437 | -.1052 | -.0676 |
| X5 | .5728 | .0071 | -.0134 | -.0045 |
| X6 | 3584.2048 | 2273.2011 | -53.2200 | -9.8127 |
| X7 | -69.0306 | -18.2479 | 3.5666 | 20.8145 |
| X8 | 1.4843 | .7778 | .0356 | -.0947 |
| X9 | 58.4822 | 11.9508 | -.2962 | .1115 |
| X1 | -1.2523 | .0659 | .0970 | .1236 |
| | X14 | X15 | X2 | X3 |
| X14 | .0748 | | | |
| X15 | .0877 | .2056 | | |
| X2 | .1540 | .1784 | 1.8173 | |
| X3 | -.0864 | -.3343 | -.7070 | 5.0888 |
| X4 | -.1431 | -.4693 | -.8673 | 6.3694 |
| X5 | -.0118 | -.0210 | -.0893 | .3522 |
| X6 | 28.3349 | 291.1766 | 233.4367 | -415.7083 |
| X7 | -6.6079 | 28.1675 | -30.5902 | 24.9717 |
| X8 | -.0786 | .0820 | -.2137 | -.5585 |
| X9 | .4245 | 3.0505 | .2494 | 10.0172 |
| X1 | .1805 | .1927 | 2.0641 | -1.0458 |

| | X4 | X5 | X6 | X7 |
|----|-----------|----------|--------------|-------------|
| X4 | 8.4600 | | | |
| X5 | .4686 | .0449 | | |
| X6 | -614.1994 | -43.1788 | 8360330.3175 | 142691.3162 |
| X7 | -1.4392 | 10.7609 | -43470.6122 | -59.2270 |
| X8 | -.6634 | -.0911 | 2109.1439 | 420.3442 |
| X9 | 12.5431 | .6321 | 28599.2051 | -54.8194 |
| X1 | -1.2948 | -.1274 | 232.6128 | |
| | X8 | X9 | X1 | |
| X8 | 2.6739 | | | |
| X9 | 8.6142 | 248.9707 | | |
| X1 | -.2458 | -.4636 | 2.4970 | |



On groups defined by Y

Analysis number 1

Stepwise variable selection

Selection rule: minimize Wilks' Lambda
 Maximum number of steps..... 30
 Minimum tolerance level..... .00100
 Minimum F to enter..... 3.84000
 Maximum F to remove..... 2.71000

Canonical Discriminant Functions

Maximum number of functions..... 1
 Minimum cumulative percent of variance... 100.00
 Maximum significance of Wilks' Lambda.... 1.0000

Prior probability for each group is .50000

----- Variables not in the Analysis after Step 0 -----

| Variable | Tolerance | Minimum Tolerance | F to Enter | Wilks' Lambda |
|----------|-----------|----------------------|------------|---------------|
| X1 | 1.0000000 | 1.0000000 | 11.2827168 | .8576901 |
| X10 | 1.0000000 | 1.0000000 | 1.3338878 | .9807614 |
| X11 | 1.0000000 | 1.0000000 | 8.7089696 | .8864674 |
| X12 | 1.0000000 | 1.0000000 | 13.0611857 | .8388725 |
| X13 | 1.0000000 | 1.0000000 | 18.7368250 | .7839807 |
| X14 | 1.0000000 | 1.0000000 | 23.9292957 | .7396989 |
| X15 | 1.0000000 | 1.0000000 | 31.6368227 | .6824786 |
| X2 | 1.0000000 | 1.0000000 | 11.5677868 | .8546172 |
| X3 | 1.0000000 | 1.0000000 | 13.0235846 | .8392618 |
| X4 | 1.0000000 | 1.0000000 | 16.0589079 | .8089565 |
| X5 | 1.0000000 | 1.0000000 | 14.0974830 | .8282836 |
| X6 | 1.0000000 | 1.0000000 | 1.2949481 | .9813125 |
| X7 | 1.0000000 | 1.0000000 | .2769621 | .9959436 |
| X8 | 1.0000000 | 1.0000000 | .0075874 | .9998884 |
| X9 | 1.0000000 | 1.0000000 | .4831227 | .9929454 |

At step 1, X15 was included in the analysis.

| | | Degrees of Freedom | Signif. | Between Groups |
|---------------|----------|--------------------|---------|----------------|
| Wilks' Lambda | .68248 | 1 1 | 68.0 | |
| Equivalent F | 31.63682 | 1 | 68.0 | .0000 |

----- Variables in the Analysis after Step 1 -----

| Variable | Tolerance | F to Remove | Wilks' Lambda |
|----------|-----------|-------------|---------------|
| X15 | 1.0000000 | 31.6368 | |

----- Variables not in the Analysis after Step 1 -----

| Variable | Tolerance | Minimum Tolerance | F to Enter | Wilks' Lambda |
|----------|-----------|-------------------|------------|---------------|
| X1 | .9945712 | .9945712 | 5.8621495 | .6275696 |
| X10 | .9430522 | .9430522 | 4.4465610 | .6400037 |
| X11 | .8722904 | .8722904 | .6826685 | .6755949 |
| X12 | .9512855 | .9512855 | 3.9791315 | .6442185 |
| X13 | .8542155 | .8542155 | 3.7445843 | .6463543 |
| X14 | .6505728 | .6505728 | 2.5376657 | .6575726 |
| X2 | .9898387 | .9898387 | 5.4568179 | .6310802 |
| X3 | .9822181 | .9822181 | 5.5951003 | .6298781 |
| X4 | .9782526 | .9782526 | 6.9419432 | .6184050 |
| X5 | .9995771 | .9995771 | 10.0771110 | .5932509 |
| X6 | .9685801 | .9685801 | .0137924 | .6823381 |
| X7 | .9756833 | .9756833 | .0848264 | .6816156 |
| X8 | .9801128 | .9801128 | .5316749 | .6771055 |
| X9 | .7879974 | .7879974 | 3.0635633 | .6526369 |

F statistics and significances between pairs of groups after step 1
 Each F statistic has 1 and 68 degrees of freedom.

| Group | Group | F | Signif. |
|-------|-------|---------|---------|
| 1 | 0 | 31.6368 | .0000 |

At step 2, X5 was included in the analysis.

| | | Degrees of Freedom | Signif. | Between Groups |
|---------------|----------|--------------------|---------|----------------|
| Wilks' Lambda | .59325 | 2 1 | 68.0 | |
| Equivalent F | 22.96852 | 2 | 67.0 | .0000 |

----- Variables in the Analysis after Step 2 -----

| Variable | Tolerance | F to Remove | Wilks' Lambda |
|----------|-----------|-------------|---------------|
| X15 | .9995771 | 26.5439 | .8282836 |
| X5 | .9995771 | 10.0771 | .6824786 |

----- Variables not in the Analysis after Step 2 -----

| Variable | Tolerance | Minimum Tolerance | F to Enter | Wilks' Lambda |
|----------|-----------|-------------------|------------|---------------|
| X1 | .9231031 | .9231031 | 2.2747431 | .5734853 |
| X10 | .6657114 | .6657114 | .1818486 | .5916208 |
| X11 | .8349422 | .8349422 | 1.9677130 | .5760759 |
| X12 | .9227792 | .9227792 | 1.8438339 | .5771278 |
| X13 | .8420361 | .8420361 | 4.6519624 | .5541893 |
| X14 | .6505647 | .6503459 | 2.1425435 | .5745979 |
| X2 | .9553181 | .9553181 | 2.6959370 | .5699691 |
| X3 | .5100696 | .5100696 | .0446096 | .5928502 |
| X4 | .4733411 | .4733411 | .2219592 | .5912625 |
| X6 | .9682201 | .9680379 | .0027096 | .5932266 |
| X7 | .9454480 | .9454480 | .0632649 | .5926828 |
| X8 | .8920641 | .8920641 | 2.6572896 | .5702899 |
| X9 | .7316463 | .7316463 | .7493418 | .5865910 |

F statistics and significances between pairs of groups after step 2
 Each F statistic has 2 and 67 degrees of freedom.

| Group | Group | 0 |
|-------|-------|------------------|
| 1 | | 22.9685 .0000 |

At step 3, X13 was included in the analysis.

| | | Degrees of Freedom | Signif. | Between Groups |
|---------------|----------|--------------------|---------|----------------|
| Wilks' Lambda | .55419 | 3 1 | 68.0 | |
| Equivalent F | 17.69763 | 3 | 66.0 | .0000 |

----- Variables in the Analysis after Step 3 -----

| Variable | Tolerance | F to Remove | Wilks' Lambda |
|----------|-----------|-------------|---------------|
| X13 | .8420361 | 4.6520 | .5932509 |
| X15 | .8536037 | 10.9834 | .6464147 |
| X5 | .9853250 | 10.9762 | .6463543 |

----- Variables not in the Analysis after Step 3 -----

| Variable | Tolerance | Minimum Tolerance | F to Enter | Wilks' Lambda |
|----------|-----------|-------------------|------------|---------------|
| X1 | .8647732 | .7888288 | .9165112 | .5464838 |
| X10 | .6570021 | .6570021 | .0301156 | .5539326 |
| X11 | .7895936 | .7050521 | 3.5319825 | .5256276 |
| X12 | .5594846 | .5105297 | .0000316 | .5541890 |
| X14 | .3411374 | .3411374 | .0009889 | .5541809 |
| X2 | .9000944 | .7933608 | 1.2322195 | .5438789 |
| X3 | .4713056 | .4713056 | .6465021 | .5487315 |
| X4 | .4614027 | .4614027 | .6248405 | .5489126 |
| X6 | .9394570 | .8084967 | .1702988 | .5527411 |
| X7 | .9105324 | .8109396 | .0253683 | .5539731 |
| X8 | .7755885 | .7320925 | .7658934 | .5477353 |
| X9 | .6793622 | .6184342 | .0827962 | .5534843 |

F statistics and significances between pairs of groups after step 3
 Each F statistic has 3 and 66 degrees of freedom.

| Group | Group | F | Signif. |
|-------|-------|---------|---------|
| | 0 | | |
| 1 | 0 | 17.6976 | .0000 |

F level or tolerance or VIN insufficient for further computation.

Summary Table

| Step | Action Entered | Removed | Vars in | Wilks' Lambda | Sig. | Label |
|------|----------------|---------|---------|---------------|-------|-------|
| 1 | X15 | | 1 | .68248 | .0000 | |
| 2 | X5 | | 2 | .59325 | .0000 | |
| 3 | X13 | | 3 | .55419 | .0000 | |

Classification function coefficients
(Fisher's linear discriminant functions)

Y = 0 1

| | | |
|------------|------------|------------|
| X13 | -1.5602495 | 2.2165942 |
| X15 | -.3201504 | 2.5487823 |
| X5 | 17.6598736 | 12.4753685 |
| (Constant) | -6.5152945 | -4.5196470 |

Canonical Discriminant Functions

| Fcn | Eigenvalue | Pct of Variance | Cum Pct | Canonical Corr | After Fcn | Wilks' Lambda | Chi-square | df | Sig |
|-----|------------|-----------------|---------|----------------|-----------|---------------|------------|----|-------|
| 1* | .8044 | 100.00 | 100.00 | .6677 | 0 | .554189 | 39.252 | 3 | .0000 |

* Marks the 1 canonical discriminant functions remaining in the analysis.

Standardized canonical discriminant function coefficients

| | Func 1 |
|-----|---------|
| X13 | .41881 |
| X15 | .61230 |
| X5 | -.56975 |

Test of Equality of Group Covariance Matrices Using Box's M

The ranks and natural logarithms of determinants printed are those of the group covariance matrices.

| Group Label | Rank | Log Determinant |
|---|------|-----------------|
| 0 | 3 | -7.626027 |
| 1 | 3 | -10.441875 |
| Pooled within-groups covariance matrix | 3 | -8.657139 |

| Box's M | Approximate F | Degrees of freedom | Significance |
|----------|---------------|--------------------|---------------|
| 25.62319 | 4.06566 | 6, | 33502.2 .0004 |

Structure matrix:

Pooled within-groups correlations between discriminating variables
and canonical discriminant functions
(Variables ordered by size of correlation within function)

| | Func 1 |
|-----|---------|
| X15 | .76049 |
| X14 | .66481 |
| X13 | .58526 |
| X5 | -.50766 |
| X12 | .48786 |
| X4 | -.44208 |
| X3 | -.38540 |
| X1 | .28878 |
| X2 | .26422 |
| X9 | .13804 |
| X8 | .13140 |
| X10 | -.13003 |
| X7 | .09939 |
| X11 | .08878 |
| X6 | .07956 |

Unstandardized canonical discriminant function coefficients

| | Func 1 |
|------------|------------|
| X13 | 2.1362270 |
| X15 | 1.6227019 |
| X5 | -2.9324167 |
| (Constant) | 1.1287615 |

Canonical discriminant functions evaluated at group means (group centroids)

| Group | Func 1 |
|-------|---------|
| 0 | -.88400 |
| 1 | .88400 |

| Case Number | Mis Val | Sel | Actual Group | Highest Probability | | 2nd Highest | | Discrim Scores | |
|-------------|---------|-----|--------------|---------------------|--------|-------------|-------|----------------|---------|
| | | | | Group | P(D/G) | P(G/D) | Group | | P(G/D) |
| 1 | | | 0 | 0 | .5543 | .6265 | 1 | .3735 | -.2926 |
| 2 | | | 1 | 1 | .3745 | .9582 | 0 | .0418 | 1.7720 |
| 3 | | | 0 ** | 1 | .4723 | .5726 | 0 | .4274 | .1653 |
| 4 | | | 1 | 1 | .2129 | .9774 | 0 | .0226 | 2.1298 |
| 5 | | | 0 | 0 | .5889 | .6473 | 1 | .3527 | -.3435 |
| 6 | | | 1 | 1 | .8604 | .8669 | 0 | .1331 | 1.0599 |
| 7 | | | 0 | 0 | .7285 | .8981 | 1 | .1019 | -1.2311 |
| 8 | | | 1 | 1 | .4117 | .9532 | 0 | .0468 | 1.7049 |
| 9 | | | 0 | 0 | .7541 | .7328 | 1 | .2672 | -.5707 |
| 10 | | | 1 | 1 | .3777 | .5008 | 0 | .4992 | .0018 |
| 11 | | | 0 | 0 | .7173 | .7156 | 1 | .2844 | -.5219 |
| 12 | | | 1 ** | 0 | .5113 | .5991 | 1 | .4009 | -.2271 |
| 13 | | | 0 | 0 | .5928 | .9247 | 1 | .0753 | -1.4187 |
| 14 | | | 1 | 1 | .9785 | .8335 | 0 | .1665 | .9110 |
| 15 | | | 0 ** | 1 | .6082 | .6585 | 0 | .3415 | .3713 |
| 16 | | | 1 | 1 | .8350 | .7676 | 0 | .2324 | .6757 |
| 17 | | | 0 ** | 1 | .5242 | .6075 | 0 | .3925 | .2471 |
| 18 | | | 1 | 1 | .9546 | .8407 | 0 | .1593 | .9410 |
| 19 | | | 0 | 0 | .6176 | .6638 | 1 | .3362 | -.3848 |
| 20 | | | 1 | 1 | .7910 | .8841 | 0 | .1159 | 1.1490 |
| 21 | | | 0 | 0 | .7303 | .7218 | 1 | .2782 | -.5393 |
| 22 | | | 1 | 1 | .9430 | .8079 | 0 | .1921 | .8125 |
| 23 | | | 0 ** | 1 | .7964 | .7515 | 0 | .2485 | .6260 |
| 24 | | | 1 | 1 | .0705 | .9915 | 0 | .0085 | 2.6924 |
| 25 | | | 0 ** | 1 | .4225 | .5361 | 0 | .4639 | .0819 |
| 26 | | | 1 | 1 | .7605 | .8911 | 0 | .1089 | 1.1888 |
| 27 | | | 0 | 0 | .5145 | .6012 | 1 | .3988 | -.2322 |
| 28 | | | 1 ** | 0 | .3853 | .5070 | 1 | .4930 | -.0158 |
| 29 | | | 0 | 0 | .3775 | .9578 | 1 | .0422 | -1.7665 |
| 30 | | | 1 | 1 | .5257 | .6085 | 0 | .3915 | .2494 |
| 31 | | | 0 ** | 1 | .7246 | .7191 | 0 | .2809 | .5317 |
| 32 | | | 1 ** | 0 | .6865 | .7005 | 1 | .2995 | -.4805 |
| 33 | | | 0 | 0 | .8060 | .8805 | 1 | .1195 | -1.1295 |
| 34 | | | 1 | 1 | .7908 | .8841 | 0 | .1159 | 1.1493 |
| 35 | | | 0 ** | 1 | .4030 | .5211 | 0 | .4789 | .0477 |
| 36 | | | 1 | 1 | .6299 | .9180 | 0 | .0820 | 1.3659 |
| 37 | | | 0 | 0 | .4957 | .9409 | 1 | .0591 | -1.5653 |
| 38 | | | 1 | 1 | .8479 | .8701 | 0 | .1299 | 1.0757 |
| 39 | | | 0 ** | 1 | .8953 | .8576 | 0 | .1424 | 1.0156 |
| 40 | | | 1 | 1 | .9477 | .8095 | 0 | .1905 | .8184 |
| 41 | | | 0 | 0 | .5207 | .6052 | 1 | .3948 | -.2417 |
| 42 | | | 1 | 1 | .5193 | .9372 | 0 | .0628 | 1.5285 |
| 43 | | | 0 | 0 | .5233 | .6069 | 1 | .3931 | -.2457 |
| 44 | | | 1 | 1 | .5251 | .6081 | 0 | .3919 | .2485 |
| 45 | | | 0 | 0 | .5332 | .6133 | 1 | .3867 | -.2609 |
| 46 | | | 1 ** | 0 | .9754 | .8188 | 1 | .1812 | -.8532 |
| 47 | | | 0 | 0 | .7993 | .8821 | 1 | .1179 | -1.1383 |
| 48 | | | 1 ** | 0 | .3889 | .5099 | 1 | .4901 | -.0224 |

| Case Number | Mis Val | Sel | Actual Group | Highest Probability Group | P(D/G) | P(G/D) | 2nd Highest Group | P(G/D) | Discrim Scores |
|-------------|---------|-----|--------------|---------------------------|--------|--------|-------------------|--------|----------------|
| 49 | | | 0 | 0 | .4543 | .9471 | 1 | .0529 | -1.6322 |
| 50 | | | 1 | 1 | .8433 | .7709 | 0 | .2291 | .6863 |
| 51 | | | 0 | 0 | .2393 | .9745 | 1 | .0255 | -2.0607 |
| 52 | | | 1 | 1 | .9124 | .7971 | 0 | .2029 | .7740 |
| 53 | | | 0 | 0 | .0122 | .9975 | 1 | .0025 | -3.3889 |
| 54 | | | 1 | 1 | .7132 | .7136 | 0 | .2864 | .5164 |
| 55 | | | 0 | 0 | .0124 | .9975 | 1 | .0025 | -3.3856 |
| 56 | | | 1 | 1 | .3898 | .9562 | 0 | .0438 | 1.7440 |
| 57 | | | 0 | 0 | .8400 | .7696 | 1 | .2304 | -.6821 |
| 58 | | | 1 | 1 | .6153 | .9207 | 0 | .0793 | 1.3865 |
| 59 | | | 0 | 0 | .2644 | .9717 | 1 | .0283 | -2.0000 |
| 60 | | | 1 | 1 | .6101 | .6596 | 0 | .3404 | .3741 |
| 61 | | | 0 | 0 | .8482 | .8701 | 1 | .1299 | -1.0755 |
| 62 | | | 1 | 1 | .2567 | .9726 | 0 | .0274 | 2.0183 |
| 63 | | | 0 | 0 | .9829 | .8321 | 1 | .1679 | -.9055 |
| 64 | | | 1 | 1 | .3545 | .9608 | 0 | .0392 | 1.8099 |
| 65 | | | 0 | 0 | .5216 | .9368 | 1 | .0632 | -1.5248 |
| 66 | | | 1 | 1 | .7729 | .7413 | 0 | .2587 | .5954 |
| 67 | | | 0 | 0 | .0003 | .9996 | 1 | .0004 | -4.4906 |
| 68 | | | 1 | 1 | .7803 | .7445 | 0 | .2555 | .6050 |
| 69 | | | 0 | 0 | .9095 | .8537 | 1 | .1463 | -.9977 |
| 70 | | | 1 | 1 | .7419 | .7272 | 0 | .2728 | .5547 |

Symbols used in plots

| Symbol | Group | Label |
|--------|-------|-------|
| 1 | 0 | |
| 2 | 1 | |

** Ayırma analizi tarafından yanlış sınıflandırılan bireyleri gösterir

AYIRMA ANALİZİ GEÇERLİLİK ANALİZİ

$$Z = (-2.9324167 \times 5) + (2.1362270 \times 13) + (1.6227019 \times 15) + 1.1287615$$

$$Y(\text{Kritik}) = 0$$

| İŞLETME NO | DURUM | AYIRMA ANALİZİ SKORU | AYIRMA ANALİZİ İLE ATANAN GRUP |
|------------|----------|----------------------|--------------------------------|
| 71 | 0 | -1.981280148 | 0 |
| 72 | 1 | 1.600304501 | 1 |
| 73 | 0 | -1.207748861 | 0 |
| 74 | 1 | 1.853416536 | 1 |
| 75 | 0 | -0.190731661 | 0 |
| 76 | 1 | 1.03110181 | 1 |
| 77 | 0 | -0.429027907 | 0 |
| 78 | 1 | 0.586357983 | 1 |
| 79 | 0 | -2.299117795 | 0 |
| 80 | 1 | -0.142007322 | 0* |
| 81 | 0 | -33.79249659 | 0 |
| 82 | 1 | 0.332702377 | 1 |
| 83 | 0 | -3.027668094 | 0 |
| 84 | 1 | 1.115908331 | 1 |
| 85 | 0 | -1.4977522 | 0 |
| 86 | 1 | 0.039729665 | 1 |
| 87 | 0 | -8.975676085 | 0 |
| 88 | 1 | 2.662642426 | 1 |
| 89 | 0 | -0.548199967 | 0 |
| 90 | 1 | 1.983189688 | 1 |
| 91 | 0 | -6.512973631 | 0 |
| 92 | 1 | 2.392872194 | 1 |
| 93 | 0 | -7.085814832 | 0 |
| 94 | 1 | -0.061348517 | 0* |
| 95 | 0 | -0.651760439 | 0 |
| 96 | 1 | -0.031310138 | 0* |
| 97 | 0 | -0.394507453 | 0 |
| 98 | 1 | 2.610077288 | 1 |
| 99 | 0 | 0.940867601 | 1* |
| 100 | 1 | 0.024090047 | 1 |
| 101 | 0 | -0.093422802 | 0 |
| 102 | 1 | -0.353834208 | 0* |
| 103 | 0 | 0.464975862 | 1* |
| 104 | 1 | 1.047372545 | 1 |
| 105 | 0 | -0.191186943 | 0 |
| 106 | 1 | 1.625082388 | 1 |

(*) AYIRMA ANALİZİ FONKSİYONU TARAFINDAN
YANLIŞ ATANAN İŞLETMELER

Architecture = Multilayer Full Feed Forward
 Error Type = Mean Absolute Error
 Batch Size = Training Set (70)
 Trn Set Size = 70
 Random Seed = 777
 Learning = On
 Layers = 4

| | Input | Hidden 1 | Hidden 2 | Output |
|-----------------|-----------|----------|----------|------------|
| Nodes | = 15 | 1 | 1 | 1 |
| Max Nodes | = 15 | 5 | 1 | 1 |
| Rule | = | BPN | BPN | BPN |
| Input Func | = Mean/SD | Dot prod | Dot prod | Dot prod |
| Transfer Func | = | Sigmoid± | Sigmoid | Thresh lin |
| InitWtsVal | = 0 | 1 | 1 | 1 |
| XferOfs | = 0 | 0 | 0 | 0 |
| Alpha | = 0 | 0.9 | 0.01 | 0.01 |
| Beta | = 0 | 0.1 | 0 | 0.1 |
| Gamma | = 0 | 0 | 0 | 0 |
| Delta | = 0 | 0 | 0 | 0 |
| Epsilon | = 0 | 0 | 0 | 0 |
| Theta | = 0 | 0 | 0 | 0 |
| Lambda | = 0 | 0 | 0 | 0 |
| Mu | = 0 | 0 | 0 | 0 |
| Sigma | = 0 | 0 | 0 | 0 |
| WtsDecay | = 0 | 0 | 0 | 0 |
| IterLimit | = 0 | 0 | 0 | 0 |
| Trial Nodes | = 1 | | | |
| Input Noise | = 0 | | | |
| Error Tolerance | = 0 | | | |

Input Arrangement = Normal
 Training sequence = Normal

Iterations = 2717

Training Set

| | | | |
|----------------------|------------|---|-----------------|
| Error | (ETrn) | = | 0 |
| Max error | (ETrnMax) | = | 0 |
| Max error sample nbr | (iETrnMax) | = | 1 |
| Classification | (CTrn) | = | 100.00% correct |

Test Set

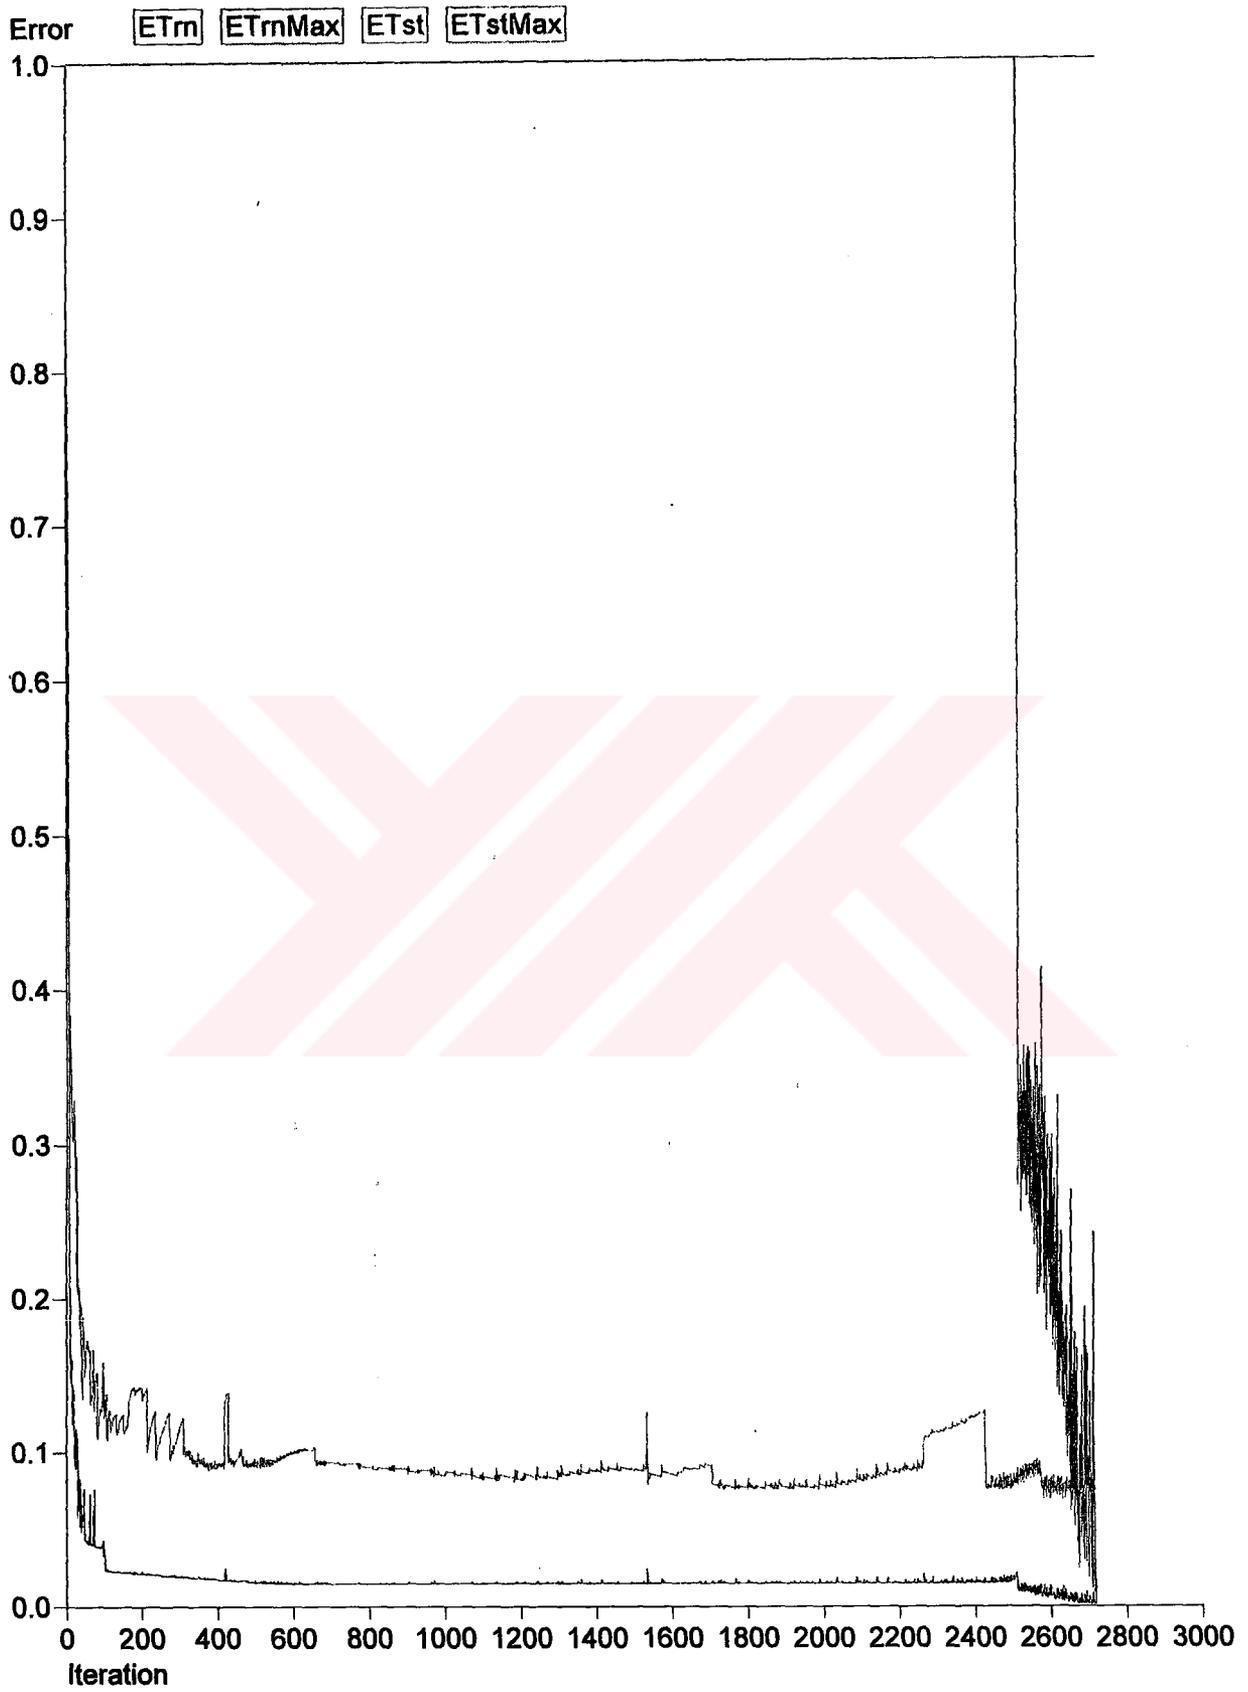
| | | | |
|----------------------|------------|---|----------------|
| Error | (ETst) | = | 0.074123 |
| Max error | (ETstMax) | = | 1 |
| Max error sample nbr | (iETstMax) | = | 26 |
| Classification | (CTst) | = | 91.67% correct |

"Correct" Classification:

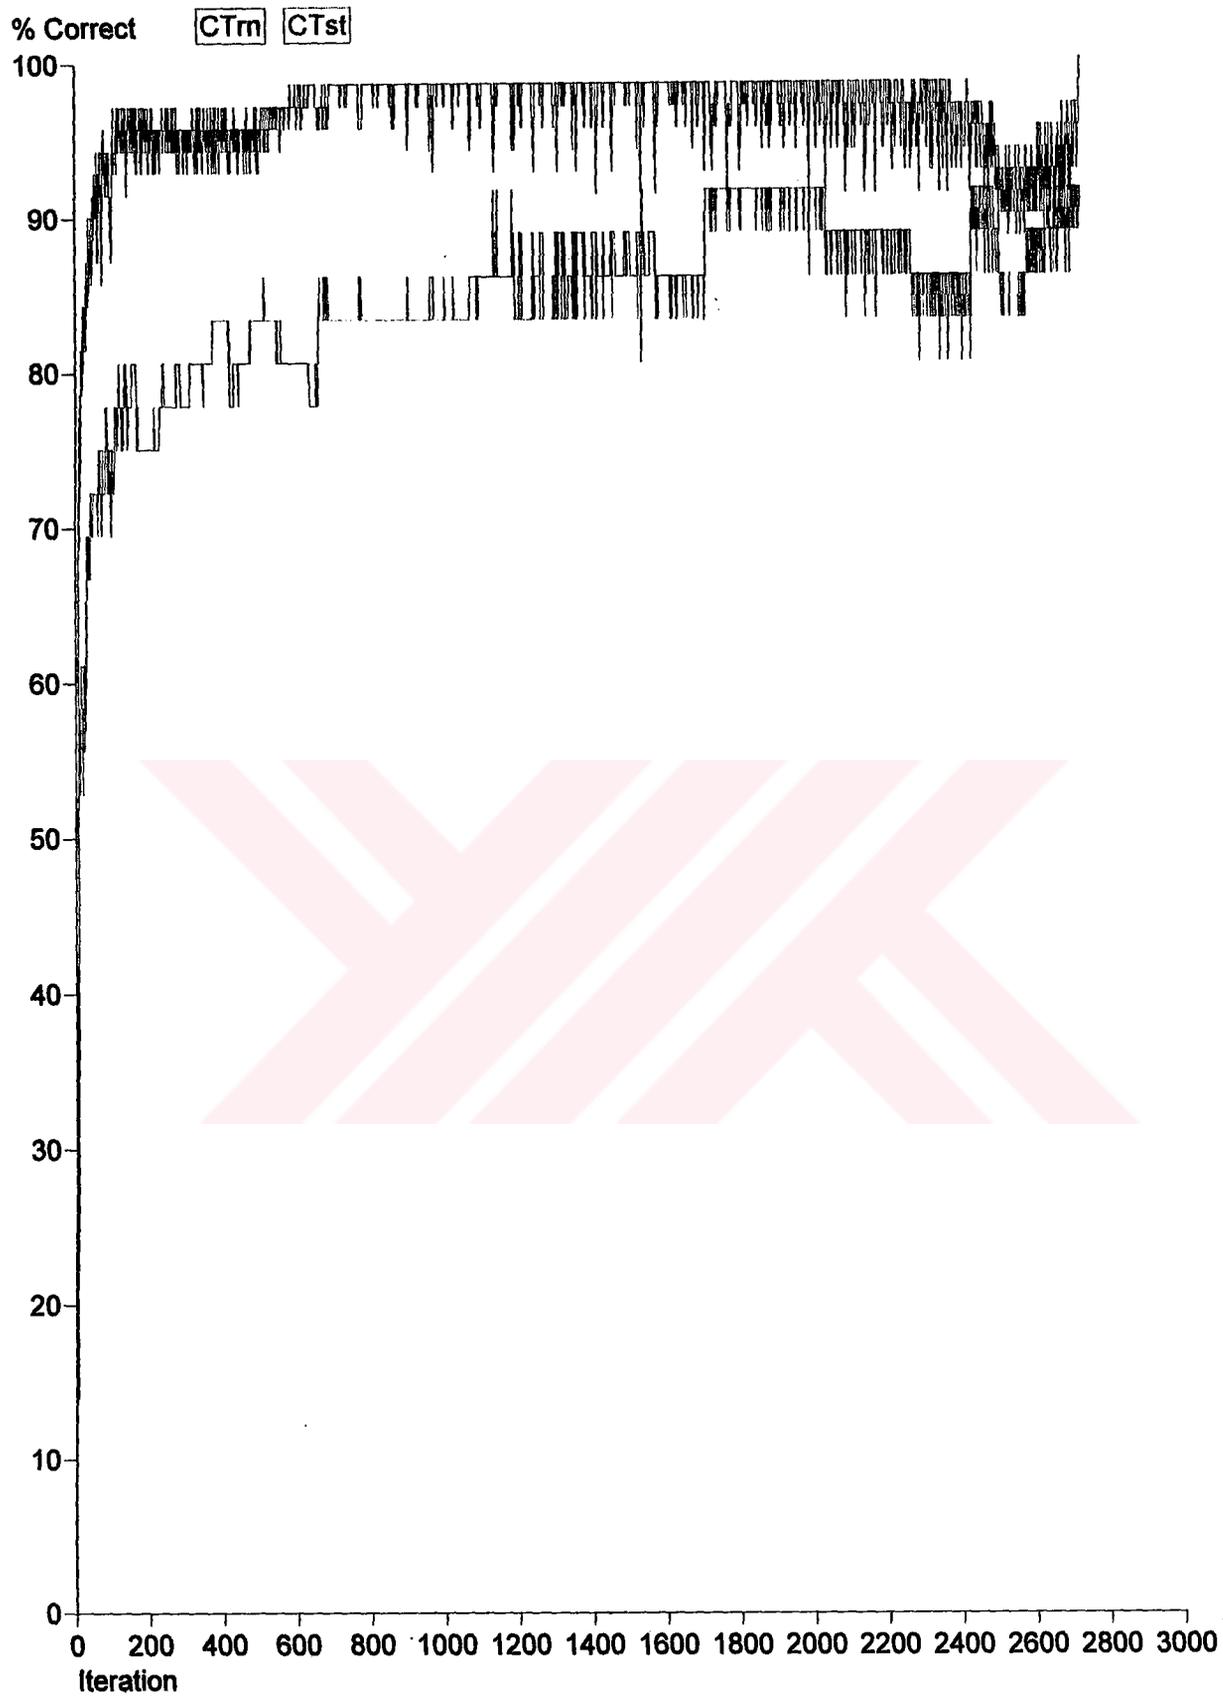
All outputs are within tolerance of desired outputs,
tolerance = 0



EK513



EK 5/4



Input Layer Preprocessing Elements (2 weights/input)

| | | | | | | | |
|----------|-----------|------------|-------------|------------|------------|----------|----------|
| 1.723201 | 1.580174 | 1.187873 | 1.348076 | 1.781502 | 2.255830 | 2.415289 | 2.908607 |
| 0.571956 | 0.211932 | 392.599080 | 2891.423032 | 141.697816 | 377.745048 | 2.387439 | 1.6352 |
| 7.918011 | 15.778804 | 4.268083 | 5.038174 | 1.262307 | 1.032768 | 0.245637 | 0.208646 |
| 0.111922 | 0.219809 | 0.029151 | 0.273469 | 0.190646 | 0.453433 | | |

Hidden Layer 1 Weights (1 bias plus 1 weight/input)

| | | | | | | | |
|-----------|----------|-----------|-----------|-----------|-----------|-----------|------------|
| -5.658763 | 7.490128 | -3.419474 | -6.123955 | -2.074470 | -1.186924 | -1.124148 | -7.428405 |
| 1.024894 | 1.662378 | -0.727744 | 2.363878 | 2.375428 | -4.251849 | -9.752328 | -14.033063 |

Hidden Layer 2 Weights (1 bias plus 1 weight/input)

| | | | | | | | |
|-----------|-----------|-----------|-----------|-----------|----------|-----------|-----------|
| -0.103748 | 0.907375 | -0.060970 | -0.880235 | -0.524706 | 0.202648 | -0.254487 | -1.373109 |
| 0.200356 | -0.262354 | 0.445315 | 1.990837 | -2.586176 | 1.251316 | 2.936448 | -0.724529 |
| -0.687924 | | | | | | | |

Output Layer Weights (1 bias plus 1 weight/input)

| | | | | | | | |
|-----------|-----------|----------|-----------|-----------|-----------|-----------|-----------|
| -0.829034 | -0.057944 | 2.069645 | -1.368334 | -0.951676 | -2.599087 | -1.418075 | -0.145545 |
| -1.939646 | 0.997535 | 0.561421 | 2.640617 | -0.943072 | 1.759597 | 0.480818 | -1.803906 |
| -2.981604 | 0.827403 | | | | | | |



Architecture = Multilayer Full Feed Forward
 Error Type = Mean Absolute Error
 Batch Size = Training Set (70)
 Trn Set Size = 70
 Random Seed = 777
 Learning = Off
 Layers = 4

| | Input | Hidden 1 | Hidden 2 | Output |
|-------------------|----------|----------|----------|----------|
| Nodes | 15 | 1 | 1 | 1 |
| Max Nodes | 15 | 5 | 1 | 1 |
| Rule | | BPN | BPN | BPN |
| Input Func | Mean/SD | Dot prod | Dot prod | Dot prod |
| Transfer Func | | Sigmoid | Sigmoid | Thresh |
| InitWtsVal | 0 | 1 | 1 | 1 |
| XferOfs | 0 | 0 | 0 | 0 |
| Alpha | 0 | 0.9 | 0.01 | 0.01 |
| Beta | 0 | 0.1 | 0 | 0.1 |
| Gamma | 0 | 0 | 0 | 0 |
| Delta | 0 | 0 | 0 | 0 |
| Epsilon | 0 | 0 | 0 | 0 |
| Theta | 0 | 0 | 0 | 0 |
| Lambda | 0 | 0 | 0 | 0 |
| Mu | 0 | 0 | 0 | 0 |
| Sigma | 0 | 0 | 0 | 0 |
| WtsDecay | 0 | 0 | 0 | 0 |
| IterLimit | 0 | 0 | 0 | 0 |
| Trial Nodes | 1 | | | |
| Input Noise | 0 | | | |
| Error Tolerance | 0 | | | |
| Input Arrangement | = Normal | | | |
| Training sequence | = Normal | | | |

Iterations = 2717

Training Set

| | | | |
|----------------------|------------|---|-----------------|
| Error | (ETrn) | = | 0 |
| Max error | (ETrnMax) | = | 0 |
| Max error sample nbr | (iETrnMax) | = | 1 |
| Classification | (CTrn) | = | 100.00% correct |

Test Set

| | | | |
|----------------------|------------|---|----------------|
| Error | (ETst) | = | 0.055556 |
| Max error | (ETstMax) | = | 1 |
| Max error sample nbr | (iETstMax) | = | 26 |
| Classification | (CTst) | = | 94.44% correct |

"Correct" Classification:

All outputs are within tolerance of desired outputs,
tolerance = 0



EK 6 / 1

Test Set

| | I11 | I12 | I13 | I14 | I15 | D1 | O1 |
|----|---------|----------|----------|---------|----------|----|----|
| 1 | 0.22352 | -0.05336 | -0.22890 | -0.716 | -0.45050 | 0 | 0 |
| 2 | 1.20003 | 0.37208 | 0.26083 | 0.26650 | 0.43961 | 1 | 1 |
| 3 | 1.22957 | 0.07730 | 0.04767 | -0.018 | -0.10190 | 0 | 0 |
| 4 | 1.191 | 0.35399 | 0.30196 | 0.29660 | 0.45591 | 1 | 1 |
| 5 | 0.95383 | 0.62177 | 0.22942 | -0.005 | -0.01350 | 0 | 0 |
| 6 | 1.14068 | 0.31654 | 0.25087 | 0.15030 | 0.27031 | 1 | 1 |
| 7 | 0.65262 | 0.44094 | 0.23881 | 0.00770 | 0.01780 | 0 | 0 |
| 8 | 0.43296 | 0.55339 | 0.44188 | 0.23080 | 0.31181 | 1 | 1 |
| 9 | 0.49274 | 0.01275 | -0.1406 | -0.144 | -0.42400 | 0 | 0 |
| 10 | 1.13368 | 0.18944 | 0.04153 | 0.00220 | 0.00481 | 1 | 1 |
| 11 | 0.00087 | 0.08628 | -15.148 | -33.37 | -0.14230 | 0 | 0 |
| 12 | 1.86191 | 0.10104 | 0.06366 | 0.06600 | 0.21931 | 1 | 1 |
| 13 | 0.29687 | -0.39578 | -0.42134 | -0.424 | -0.58710 | 0 | 0 |
| 14 | 2.10018 | 0.41867 | 0.18928 | 0.13910 | 0.50551 | 1 | 1 |
| 15 | 0.38476 | 0.07632 | -0.00845 | -0.129 | -0.21620 | 0 | 0 |
| 16 | 1.10739 | 0.29265 | 0.19221 | 0.08980 | 0.31861 | 1 | 1 |
| 17 | 0.00893 | -0.02520 | -4.0089 | -3.369 | -0.05930 | 0 | 0 |
| 18 | 1.11941 | 0.53293 | 0.46727 | 0.45140 | 0.59021 | 1 | 1 |
| 19 | 0.13528 | 0.60015 | -0.05285 | -0.138 | -0.03830 | 0 | 0 |
| 20 | 0.81965 | 0.29966 | 0.27116 | 0.33260 | 0.29261 | 1 | 1 |
| 21 | 0.2416 | -0.82654 | -1.34385 | -1.362 | -1.52350 | 0 | 0 |
| 22 | 0.88235 | 0.53109 | 0.48781 | 0.42480 | 0.45491 | 1 | 1 |
| 23 | 0.01300 | 0.02280 | -2.99488 | -3.432 | -0.10210 | 0 | 0 |
| 24 | 0.89992 | 0.23330 | 0.18457 | 0.09680 | 0.29311 | 1 | 1 |
| 25 | 0.40513 | 0.46636 | 0.00214 | -0.103 | -0.09410 | 0 | 0 |
| 26 | 0.55335 | 0.60848 | 0.26709 | 0.02720 | 0.03871 | 0 | * |
| 27 | 1.59494 | 0.52801 | 0.09949 | 0.04370 | 0.26940 | 0 | 0 |
| 28 | 2.0783 | 0.36771 | 0.29663 | 0.28910 | 0.64451 | 1 | 1 |
| 29 | 1.26227 | 0.25760 | 0.18811 | 0.14800 | 0.29360 | 0 | 1 |
| 30 | 1.05992 | 0.27103 | 0.23891 | 0.05140 | 0.14871 | 1 | 1 |
| 31 | 1.13003 | 0.36163 | 0.12088 | 0.05440 | 0.14890 | 0 | 0 |
| 32 | 1.17118 | 0.25475 | 0.17668 | 0.03490 | 0.14261 | 1 | 1 |
| 33 | 0.97935 | 0.46840 | 0.22744 | 0.09120 | 0.17490 | 0 | 0 |
| 34 | 1.463 | 0.35353 | 0.20753 | 0.20810 | 0.73871 | 1 | 1 |
| 35 | 1.32905 | 0.17335 | 0.05657 | 0.03040 | 0.08800 | 0 | 0 |
| 36 | 1.61645 | 0.38335 | 0.26749 | 0.25200 | 0.68291 | 1 | 1 |

* Yapay sinir ağı için kontrol verilerinde tespit edilmiş yanlış örnekler gösterir.

| | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | |
|--------------------|----------------------|---------------|---------------|---------------------------------|----------------------|---------------|--|---------------|---------------|--------------------------------|----------------------|--------------|--|---------------|---------------|--------------------------------|----------------|---------------------|---------------------------------|----------------------|---------------|---------------------------------|----------------------|---------------|--------------------------------|----------------------|---------------|---------------------------------|--------|---------------|---------------|--------------------------------|----------------------|---------------|---------------------------|----------------------|---------------|---------------------------------|---------------------|---------------|---------|---------------------------------|----------------------|---------------|---------------------------------|----------------------|---------------|--------------------------------|----------------------|---------------|--------------------------------|---------------------|---------------|--------------------------------|----------------------|---------------|---------------------------------|----------------------|---------------|--------------------------------|----------------------|---------------|--|---------------|---------------|---------------------------------|---------------------|---------------|--------------------------------|----------------------|---------------|---------------------------------|----------------------|---------------|---------------------------------|----------------------|---------------|---------------------------------|----------------------|---------------|--------------------------------|--------|---------------|---------------|--------------------------------|----------------------|---------------|---------------------------------|--------|---------------|---------------|---------------------------------|----------------------|---------------|---------------------------------|--------|---------------|---------------|---------------------------------|----------------------|---------------|
| 110 | 19 | 18 | 17 | 16 | 15 | 14 | 13 | 12 | 11 | 10 | 9 | 8 | 7 | 6 | 5 | 4 | 3 | 2 | 1 | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | | |
| 1.49240.97161.0204 | 1.81290.644490.03296 | 13.8810.41287 | 0.28580.62877 | 3.05022.56230.29340.37450.27247 | 17.34543.82951.84258 | 1.38681.64947 | 0.84920.46823.10773.44630.775090.79178 | 40.9472.07154 | 1.70455.46709 | 3.2232.31590.18000.29050.22516 | 21.161233.5772.29283 | 3.09621.5371 | 1.58670.36961.44641.56160.609620.97354 | 18.1581.06458 | 3.06102.44338 | 1.86011.15200.4800.57640.36567 | 2.57568144.592 | 0.10420.99211.79824 | 1.68461.34021.57642.50970.71507 | 1.0440225.5140.86246 | 1.49562.29051 | 0.82800.50741.62832.11960.67944 | 1.9866712.4971.00169 | 0.68161.35068 | 0.74020.45942.2064.94860.83189 | -34.8296.53871.79425 | 0.64072.93116 | 1.81941.06470.63650.87360.46627 | 1.0429 | 520.321.83412 | 1.03352.12409 | 1.98801.23360.4643.87160.79473 | -0.55620.09410.00462 | 0.00100.00426 | 1.77561.15380.78320.43922 | 28.59129.87952.38739 | 4.55423.32023 | 0.85390.29610.62053.66310.78555 | -429.0516.8382.6108 | 0.19391.38435 | 1.30769 | 15.97010.9900.06100.16810.14397 | 175.93932.0821.34162 | 1.48431.30769 | 0.54080.20150.64851.04980.51217 | -0.16778.86630.79016 | 0.14270.27732 | 9.34026.76760.0530.07300.06809 | 69.74468.54511.77108 | 1.15180.87954 | 0.18980.12232.2483.62730.78389 | -26.80026.9812.6187 | 0.16071.11796 | 13.4447.89390.0670.21360.17604 | 10.04334.90791.17494 | 9.66621.07088 | 13.2954.00950.02401.28840.56303 | -19.6290.67470.09298 | 0.01520.02975 | 1.9470.92181.80172.36140.70250 | 2.0458916.8901.40531 | 2.68543.02502 | 1.01210.99841.15541.25550.556650.53476 | 34.1850.78136 | 0.84610.91381 | 0.77840.43201.20531.57480.61162 | 1.07766.38761.51841 | 1.60721.42479 | 1.02160.95561.8092.86180.74105 | 1.43507118.773.33254 | 3.29416.15942 | 21.45814.8960.03480.07250.06762 | 163.16157.3462.97714 | 29.7502.22903 | 1.78050.98660.53070.57140.36362 | 3.7289396.1432.10101 | 3.32231.98354 | 0.95540.62151.67951.72530.63307 | 1.2778944.6321.80006 | 19.0622.88864 | 1.88501.21150.8991.42290.58728 | 2.2279 | 40.9211.61539 | 3.84802.73804 | 1.07050.96892.3142.48750.71326 | 1.2280749.2131.64876 | 4.06624.08455 | 1.83120.60420.44580.95630.48883 | 2.6385 | 27.8712.34678 | 1.78551.91594 | 1.67281.30421.32541.42580.58776 | 5.487769.63201.60059 | 26.5483.54897 | 1.04310.89031.07451.17410.54004 | 1.1762 | 28.8462.57679 | 2.75612.88954 | 2.22031.21560.62480.67640.40351 | 13.716219.1911.95396 | 11.5472.70995 |

Test Set

EK 6/2