



Hacettepe Üniversitesi Sosyal Bilimler Enstitüsü
İktisat Anabilim Dalı

**ÖRÜNTÜ TANIMA YÖNTEMİYLE BANKACILIK SEKTÖRÜ İÇİN
BİR ERKEN UYARI MODELİ:
TÜRKİYE UYGULAMASI (1997-2001)**

Asım KURT

Yüksek Lisans Tezi

Ankara, 2011

ÖRÜNTÜ TANIMA YÖNTEMİYLE BANKACILIK SEKTÖRÜ İÇİN BİR ERKEN UYARI
MODELİ: TÜRKİYE UYGULAMASI (1997-2001)

Asım KURT

Hacettepe Üniversitesi Sosyal Bilimler Enstitüsü
İktisat Anabilim Dalı

Yüksek Lisans Tezi

Ankara, 2011

KABUL VE ONAY

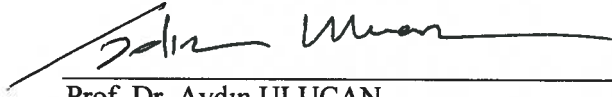
Asım KURT tarafından hazırlanan "Örüntü Tanıma Yöntemiyle Bankacılık Sektörü İçin Bir Erken Uyarı Modeli: Türkiye Uygulaması (1997-2001)" başlıklı bu çalışma, 30.06.2011 tarihinde yapılan savunma sınavı sonucunda başarılı bulunarak jürimiz tarafından Yüksek Lisans Tezi olarak kabul edilmiştir.



Doç. Dr. Naci CANPOLAT (Başkan)



Doç. Dr. İbrahim ÖZKAN (Danışman)



Prof. Dr. Aydın ULUCAN



Doç. Dr. Nasip BOLATOĞLU



Doç. Dr. Timur Han GÜR

Yukarıdaki imzaların adı geçen öğretim üyelerine ait olduğunu onaylım.

Prof. Dr. İrfan ÇAKIN

Enstitü Müdürü

BİLDİRİM

Hazırladığım tezin/raporun tamamen kendi çalışmam olduğunu ve her alıntıya kaynak gösterdiğimi taahhüt eder, tezimin/raporumun kağıt ve elektronik kopyalarının Hacettepe Üniversitesi Sosyal Bilimler Enstitüsü arşivlerinde aşağıda belirttiğim koşullarda saklanmasına izin verdiğimi onaylarım:

- Tezimin/Raporumun tamamı her yerden erişime açılabilir.
- Tezimin/Raporum sadece Hacettepe Üniversitesi yerleşkelerinden erişime açılabilir.
- Tezimin/Raporumun 2 yıl süreyle erişime açılmasını istemiyorum. Bu sürenin sonunda uzatma için başvuruda bulunmadığım takdirde, tezimin/raporumun tamamı her yerden erişime açılabilir.

30.06.2011



Asım KURT

ÖZET

KURT, Asım. “*Örüntü Tanıma Yöntemiyle Bankacılık Sektörü İçin Bir Erken Uyarı Modeli: Türkiye Uygulaması (1997-2001)*”, Yüksek Lisans Tezi, Ankara, 2011.

Finansal piyasalarda güven ve istikrarın sağlanabilmesinin önemli şartlarından biri bankacılık sektöründe oluşabilecek sorunların zamanında fark edilerek gerekli önlemlerin alınabilmesidir. Bu çalışmanın amacı, bankaların finansal başarısızlıklarını öngören bir erken uyarı sistemi geliştirilmesi ve başarısızlığa uğrama nedenlerinin analiz edilmesidir. Sağlıklı öngörüler yapabilen bir erken uyarı sistemi, bankacılık düzenleme ve denetleme otoriteleri başta olmak üzere banka sahipleri, yatırımcılar ve bağımsız denetçiler gibi pek çok paydaşa finansal başarısızlıktan kaynaklanan riskleri yönetebilme veya en azından azaltabilme olanağı sunacaktır. Bu amaçla, çalışmada 1997-2001 dönemi içerisinde faaliyet gösteren ve 19’u finansal başarısızlığa uğramış toplam 40 özel ticari bankaya ait finansal oranlar kullanılarak karar ağacı kurulmuştur. Finansal başarısızlığa ilişkin kolay anlaşılabilir ‘eğer-ise’ şeklinde kurallar üretilmesine olanak tanınması ve Türk bankacılık sistemi üzerine yapılan uygulamalarda kullanılmamış olması nedeniyle karar ağacı yöntemi çalışmada tercih edilmiştir.

Sınıflandırma ve regresyon ağaçları (CART), özellikle sınıflandırma probleminin çözümünde yaygın olarak kullanılan bir karar ağacı modelidir. Çalışmada CART ile kurulan modelle, bankaların başarısızlığa uğrama durumlarının 1 yıl öncesinden öngörülmesine ve çıkarılan kurallar ile başarısızlığa uğrama nedenlerinin analiz edilmesine çalışılmıştır.

Çalışma sonucunda, örnekleme yöntemlerine göre değişmekle birlikte kurulan model, %73-%78 oranında finansal başarısızlığı 1 yıl öncesinden öngörebilmiştir. Çalışmada kullanılan sınıflandırma ve regresyon ağacı yöntemi, finansal başarısızlığın öngörülmesinde istatistiksel modellerden daha başarılı bulunmuştur. Ayrıca modelden çıkarılan kurallar, bankaların 1997-2001 dönemleri içerisinde faiz yükselişlerine karşı duyarlı olduklarını ve sermaye yapısı güçlü olmayan bankaların bu dönemde yaşanan yüksek faize karşı ayakta kalamadığını göstermektedir.

Anahtar Sözcükler: Finansal Başarısızlık, Banka, Karar Ağacı, CART, Kolmogorov-Smirnov Testi

ABSTRACT

KURT, Asım. “Early Warning System for Banking Sector using Pattern Recognition Technique: The Turkish Case (1997-2001)”, Master’s Thesis, Ankara, 2011.

One of the most important requirements of confidence and stability in financial markets is foreseeing possible financial distress in banking sector and getting necessary actions timely. The aim of this study is to develop an early warning system for predicting financial failure in banks and to analyze the reasons of financial failure. An early warning system, which makes reliable predictions, will provide good information to various decision makers including regulation and supervision agencies, bank holders, investors and auditors in order to assess and manage the risks of financial failure. For this purpose, a sample of 40 privately-owned commercial banks balance sheets is used. The time span of the data set covered 1997-2001 where 19 banks failed. As a methodology for prediction decision tree is preferred since it produces easily understandable ‘if-then’ rules for financial failures.

A set of financial ratios were created and Classification and regression tree (CART), a popular decision tree technique, was applied to obtain failure classifications of banks 1 year before failure happens. The reasons for the bank failures were analyzed by means of extracted rules from the tree.

As a result, the setup model correctly predicted %73-78 of failed banks 1 year before failure, varying ratios with different sampling methods. In the study, it is observed that CART is superior to statistical methods in predicting financial failure. Furthermore, rules extracted from model, showed that banks were sensitive to rising interest rates during 1997-2001 and banks with weak capital structure were not able to survive with high interest rates in that period.

Key Words

Financial Failure, Bank, Decision Trees, CART, Kolmogorov-Smirnov Test

İÇİNDEKİLER

KABUL VE ONAY	i
BİLDİRİM	ii
ÖZET	iii
ABSTRACT	iv
İÇİNDEKİLER	v
KISALTMALAR DİZİNİ	viii
TABLolar DİZİNİ	ix
ŞEKİLLER DİZİNİ	x
GİRİŞ	1

1. BÖLÜM

FİNANSAL BAŞARISIZLIĞIN ÖNGÖRÜLMESİ: TEMEL KAVRAMLAR VE TAHMİN YÖNTEMLERİ	6
1.1. MODEL KURMADA KULLANILAN GENEL METODOLOJİ.....	7
1.2. FİNANSAL ORANLAR VE KULLANILAN DİĞER VERİLER	8
1.2.1. CAMELS	9
1.3. ÖZELLİK SEÇİMİ VE ÖZELLİK SEÇİM YÖNTEMLERİ	10
1.3.1. Doğru Özellikleri Bulmanın Önemi.....	11
1.3.2. Özellik Seçimi Teknikleri, Filtre ve Sarmalayıcı Yaklaşım	12
1.3.3. Finansal Başarısızlığın Öngörüsü Alanında Özellik Alt Kümesi Belirleme Yöntemleri	13
1.4. TİP-I VE TİP-II HATA.....	14
1.5. HATALI SINIFLANDIRMA MALİYETİ.....	14
1.6. ÖRNEKLEME YÖNTEMLERİ.....	15
1.7. TAHMİN YÖNTEMLERİ.....	17
1.7.1. İstatiksel Teknikler.....	17
1.7.2. Yapay Sinir Ağları	23

1.7.3. Durum Tabanlı Çıkarsama	28
1.7.4. Karar Ağaçları.....	31
1.7.5. Yöneylem Araştırması	34
1.7.6. Genetik Algoritmalar	35
1.7.7. Kaba Kümeler	37
1.7.8. Bulanık Mantık, Destek Vektör Makineleri Ve Diğer Yöntemler	40
1.7.9. Esnek Hesaplama (Soft Computing).....	42

2. BÖLÜM

TÜRKİYE'DE YERLEŞİK BANKALAR HAKKINDA ÇALIŞMALAR.....	46
2.1. KASIM 2000 VE ŞUBAT 2001 KRİZLERİ	46
2.2. TÜRK BANKACILIK SEKTÖRÜNDE FİNANSAL BAŞARISIZLIK ÖNGÖRÜSÜ ÇALIŞMALARI	48

3. BÖLÜM

TÜRKİYE'DE YERLEŞİK BANKALAR İÇİN BİR AMPİRİK UYGULAMA.....	52
3.1. ÇALIŞMANIN AMACI	52
3.2. ÇALIŞMADA KULLANILAN VERİ SETİ	53
3.3. METODOLOJİ	57
3.3.1. Sınıflandırma ve regresyon ağaçları (CART)	57
3.3.2. Kolmogorov-Smirnov (KS) Testi	63
3.4. SINIFLANDIRMA VE REGRESYON AĞACININ KURULMASI	65
3.4.1. KS Testi İle Özellik Seçimi	65
3.4.2. CART Modelinin Test Edilmesi	66
3.4.3. CART Modelinin Karar Alma Sürecinin Değerlendirilmesi	70
3.5. MODELİN ÖNCEKİ ÇALIŞMALARLA KARŞILAŞTIRILMASI	71
SONUÇ VE DEĞERLENDİRME.....	75

EKLER	77
Ek-1: TBB Finansal Oranların Hesaplanmasında Kullanılan Formüller	77
Ek-2: Bir Tanesini Dışarıda Bırakma Yöntemiyle Elde Edilen Sonuçlar	79
Ek-3: TBS'ne Yönelik Yapılan Çalışmalarda Kullanılan Finansal Oranlar	80
KAYNAKÇA	82

KISALTMALAR DİZİNİ

- ABD : Amerika Birleşik Devletleri
BDDK : Bankacılık Düzenleme ve Denetleme Kurumu
CART : Classification and Regression Tree
CBR : Case-based Reasoning
DTÇ : Durum Tabanlı Çıkarsama
DVM : Destek Vektör Makineleri
FDIC : The Federal Deposit Insurance Corporation
GA : Genetik Algoritma
GSYİH: Gayri Safi Yurtiçi Hasıla
IMF : International Monetary Fund
TBB : Türkiye Bankalar Birliği
TCMB : Türkiye Cumhuriyet Merkez Bankası
TMSF : Tasarruf Mevduatı Sigorta Fonu
VZA : Veri Zarflama Analizi
YSA : Yapay Sinir Ağları

TABLolar DİZİNİ

Tablo 1 Gerçek ve Tahmin Edilen Grup Sınıflandırma Tablosu	14
Tablo 2 TMSF'ye devredilen bankalar ve devredilme tarihleri (TMSF, 2011).....	54
Tablo 3 Finansal oranlara ilişkin tanımlayıcı istatistikler	56
Tablo 4 KS Testi Sonuçları (D-istatistiğine göre sıralı).....	66
Tablo 5 Bir tanesini dışarıda bırakma yöntemiyle elde edilen sonuçlar	68
Tablo 6 10 bölmeli çapraz doğrulama yöntemiyle elde edilen sonuçlar	68
Tablo 7 Yerine koyma yöntemiyle elde edilen sonuçlar.....	70
Tablo 8 Canbaş, Çabuk ve Kılıç (2005) ve CART modeli sonuçlarının karşılaştırılması	71
Tablo 9 Yıldız ve Akkoç (2009) ile CART modeli sonuçlarının karşılaştırılması	72
Tablo 10 CART modelinde yer alan düğümlerdeki asıl ve vekil değişkenler	73

ŞEKİLLER DİZİNİ

Şekil 1 Bir tanesini dışarıda bırakma örnekleme yöntemi	16
Şekil 2 k bölmeli çapraz doğrulama örnekleme yöntemi.....	16
Şekil 3 Yapay sinir ağlarında düğüm (sinir hücresi).....	24
Şekil 4 Durum tabanlı çıkarsama yöntemi	29
Şekil 5 Kopya alt ağaçlar taşıyan bir ağaç yapısı.....	33
Şekil 6 Kaba kümeler yaklaşımı	38
Şekil 7 10 bölmeli çapraz doğrulama sonucu oluşturulan nihai ağaç yapısı.....	69

GİRİŞ

Ülkelerin ekonomik gelişme sürecinde finansal piyasalar ve kurumların çok önemli bir fonksiyon yerine getirdikleri literatürde geniş bir şekilde vurgulanmakta ve bu durum bir çok bilimsel çalışmanın da konusunu oluşturmaktadır. Bu çalışmalardaki ortak kanaat, iyi işleyen finansal kurumların ve piyasaların uzun dönemde ekonomik büyümeye katkı yapacağıdır (Ağır, Peker ve Kar, 2009).

Bankalar, finansal kurumlar içerisinde önemli bir yer tutmaktadır. Bu durum Türkiye’de daha da belirgindir. 2010 yılı sonu itibariyle bankacılık sektörünün toplam aktifleri 1 trilyon TL’yi aşarken ve finansal sektörün toplam aktiflerine oranı %77,2 olarak gerçekleşmiştir (Bankacılık Düzenleme ve Denetleme Kurumu [BDDK], 2011). Diğer finansal kurumların yeterince gelişmemiş olduğu ve önemli bir bölümünün bankalar tarafından kurularak işletildiği göz önüne alındığında, bankacılık sektörünün Türkiye açısından konumu daha iyi anlaşılacaktır (Yıldız ve Akkoç, 2009).

Bankacılık sektörü finansal kaynakların tahsisinde ve ekonomik büyümede oldukça önemli bir rol oynarken, kriz ve istikrarsızlıklara karşı aşırı derecede duyarlıdır. Finansal krizler, özellikle gelişmekte olan ülkelerde ekonomik çıktı ve toplumsal refah açısından oldukça maliyetli olabilmektedir. 1970-2007 yılları arasında farklı ülkelerde meydana gelen 124 adet sistemik bankacılık krizinin maliyetinin GSYİH’na oranı, ortalama olarak %13,3’ü bulurken, bu oran bazı ülkelerde %55’lere kadar çıkabilmiştir (Laeven ve Valencia, 2008).

Bu maliyetlerin önlenmesi adına, finansal sektör politikalarına ilişkin reform çalışmalarında etkin düzenleme ve denetleme mekanizmalarının oluşturulması gerekliliği ifade edilmektedir. Bankaların, ödeme sistemleri içerisinde oynadıkları merkezi rol, banka sahipleri ve mevduat sahipleri arasındaki asimetrik bilgi yapısı ve üstlendikleri kamu görevi de denetim gereksinimlerinin artmasına neden olan unsurlar olmuştur (Ağır, Peker ve Kar, 2009).

Finansal piyasaların gün geçtikçe birbirlerine entegre olmaları ve tüm dünyada izlenen finansal serbestleşme politikaları bankacılık sektörünün oldukça kompleks bir yapıya bürünmesine ve daha riskli hale gelmesine neden olmuştur. Dolayısıyla tüm dünyada sağlıklı ve istikrarlı bir finansal sektör oluşturulabilmesi, uluslararası alanda birlikte hareket edilmesiyle mümkün hale gelmiştir. Bu doğrultuda, tüm dünyada bankacılık sektörünün gözetim ve denetimi çalışmalarına yön vermek üzere Basel Bankacılık Denetim Komitesi kurulmuştur. Komite, ortaya koyduğu

kriterlerle uluslar arası alanda bankacılık sektörüne yönelik denetim, gözetim ve düzenleme faaliyetlerinin belli bir standarda kavuşturulmasına çalışmaktadır (Çinko ve Avcı, 2008).

Finansal Krizler ve Bankacılık Sektörü

Son yirmi yılda hem gelişmiş hem de gelişmekte olan ekonomilerde ortaya çıkan finansal krizlerde oldukça büyük bir artış yaşanmıştır. Laeven ve Valencia (2008) 1970-2007 yılları arasında tespit edilen 128 sistemik bankacılık krizinin 81 tanesinin 1990'lı yıllardan sonra gerçekleştiğini, 15 tanesinin para krizi ile 5 tanesinin ise hem para hem de borç krizleri ile birleştiğini gözlemlemiştir. Ayrıca 1970'den sonra gerçekleşen 93 krizden 51 tanesi başka ülkelere de yayılım göstermiş ve sorun artık küresel bir hal almıştır (Tunay, 2010). Son örneği Lehman Brothers'ın Eylül 2008'de iflas etmesiyle açığa çıkan ve 2008 son çeyreği ve 2009'un Ocak-Eylül döneminde çok etkili olan küresel kriz, IMF raporlarına göre 3 trilyon 283,5 milyar dolara mal olmuştur (IMF, 2010). Amerika'da mortgage piyasası krizi ile başlayan süreçte 2008 yılından bugüne finansal başarısızlığa uğrayarak FDIC'ye devredilen banka sayısı ise 367'ye ulaşmıştır (FDIC, 2011).

Türkiye'de ise uygulamaya konulan istikrar programlarının çeşitli nedenlerle sonuçlandırılmaması nedeniyle 1990'lı yıllardan itibaren sıklaşan aralıklarla krizlerle karşı karşıya kalınmıştır. Makro ekonomik istikrarsızlık, bankacılık sektöründeki küçük ve parçalı yapı, kamu bankalarının bozucu etkisi ve risk yönetimi konusundaki eksiklikler gibi temel yapısal sorunlar, 2001 yılı Şubat ayında yaşanan para krizinin derinleşmesine ve sistemik bankacılık krizine dönüşmesine neden olmuştur (BDDK, 2009).

Finansal kriz ilk olarak Kasım 2000'de kendini hissettirmiştir. Bu tarihte bankalararası piyasada gecelik borçlanma basit faizi yaklaşık üç kat artarak ortalama %110.8'e çıkmıştır (Uygur, 2001). TCMB, döviz hedef alan yoğun spekülasyon saldırıyı çok yüksek faiz, önemli döviz rezervi kayıplarıyla ve yüksek maliyetli IMF kredisi ile geri püskürtebilmiş ancak benzer bir saldırıya karşı savunma gücünü büyük ölçüde kaybetmiştir (Uygur, 2001). Bu dönemde riskli olduğu bilinen ve IMF programında yeniden yapılandırılması öngörülen bankacılık sektöründe döviz ve vade uyumsuzluklarına karşı konulan bazı kuralların uygulanamadığı bizzat TCMB kaynaklı açıklamalardan bilinmekteydi (Uygur, 2001). Bankacılık kesiminin 2000 Eylül ayı sonunda bilanço döviz açık pozisyonu kural olarak konulan %20 oranının tam 10 katını bulmuştu. Yasaya rağmen Bankalar döviz borçlarının riskini döviz forward kontratlarıyla karşıladıklarını söyleyip bu kontratları da bilanço dışı nazım hesaplarda rapor etmekteydiler. Ancak forward kontratlar yerli ve/veya holding firmalarıyla yapılmakta ve gerçekte döviz borçlarının ancak çok küçük bir bölümünü karşılamaktaydı. Haliyle, bankaların önemli döviz

riski taşıdıkları özellikle dış borç veren yabancı kuruluşlar tarafından bilinmekteydi (Uygur, 2001).

Kasım krizinin aşılmasından tam üç ay sonra Şubat 2001’de yaşanan siyasi bir gerginlik, ikinci bir spekülasyon saldırıyı başlatmış ve bu kez para krizi yaşanmıştır. 21 Şubat’ta bankalararası para piyasasında gecelik faiz %6200’e kadar yükselmiş ve ortalama %4018,6 olarak gerçekleşmiştir. Şubat krizinde döviz rezervleri iyice eriyen TCMB yapılan saldırıya dayanma gücü kalmayınca, 21 Şubat gecesi kurun dalgalanmaya bırakıldığını açıklamıştır. Bu açıklamayla birlikte on gün içinde dolar kurundaki artış %40’a ulaşmıştır (Uygur, 2001). Bu durum, faize ve döviz kuruna aşırı derecede duyarlı olan bankacılık kesiminde ağır tahribatlarla birlikte ciddi bir güvensizlik ortamı oluşmasına neden olmuştur.

Güven bunalımının aşılabilmesi için finansal açıdan problemlili bankaların sistemden ayıklanmasını da içerecek şekilde 2001 yılı Mayıs ayında “Bankacılık Sektörü Yeniden Yapılandırma Programı” uygulamaya konulmuştur. Program ile kamu bankalarının yeniden yapılandırılması, TMSF’ye devredilen bankaların çözümlenmesi, özel bankacılık sisteminin rehabilitasyonu, gözetim ve denetim çerçevesinin güçlendirilmesi ve sektörde etkinliğin artırılması amaçlanmıştır (BDDK, 2009). Yaşanan devirlerle birlikte, bankacılık sektörünün yeniden yapılandırılmasının kamu maliyesine getirdiği ek yük 39,3 milyar dolar, bunun GSYİH’ya oranı ise %26,6’yı bulmuştur (BDDK, 2003).

Uzaktan Gözetim ve Erken Uyarı Sistemleri

Bankacılık gözetim ve denetim uygulamaları ülkeler arasında farklılık gösterse de genel kabul gören iki tür uygulama bulunmaktadır. Bunlar “yerinde denetim” ve “uzaktan gözetim” faaliyetleridir. Bankaları takip etmenin en etkin yöntemi olarak kabul edilen “yerinde denetim” faaliyetleri kamu otoritelerinin yetkili kıldığı kişiler tarafından bizzat bankada gerçekleştirilirken, “uzaktan gözetim” ise bankalardan alınan finansal raporlar ve diğer bilgilerin uzman kişiler veya sistemler tarafından yorumlanmasıyla gerçekleştirilmektedir (Çinko ve Avcı, 2008). İçlerinde Amerika ve Türkiye’nin de bulunduğu bir çok ülkede “yerinde denetim” faaliyetleri Sermaye Yeterliliği (*Capital Adequacy*), Varlıklar Kalitesi (*Assets Quality*), Yönetim Yeterliliği (*Management Adequacy*), Gelirler (*Earnings*), Likidite (*Liquidity*) ve Piyasa Riskine Duyarlılık (*Sensitivity to Market Risk*) bileşenlerinden oluşan CAMELS dereceleme sistemi kullanılarak gerçekleştirilmektedir. Yerinde denetim etkin bir takip yöntemi olmasına rağmen; masraflı ve uzun bir süreç gerektirmektedir. Sonunda elde edilen CAMELS dereceleri ise kısa bir süre içerisinde geçersiz hale gelebilmektedir (Cole ve Gunther, 1995). Bu

durum, bankaların finansal durumlarının takip edilebilmesi açısından uzaktan gözetim faaliyetlerinin önemini daha da arttırmaktadır.

Uzaktan gözetim alanında uzman kişiler tarafından yapılan değerlendirmeler çokça kullanılmakla birlikte; içerdikleri subjektif yorumlar ve insan doğasından kaynaklanan hata olasılıklarını beraberinde getirmelerinden dolayı tek başlarına yeterli görülmemektedir. Bu durum, birçok bankacılık otoritesini, bankaların finansal risklerini öngörmeye yönelik erken uyarı sistemleri geliştirmeye zorlamıştır (Chaudhuri ve De, 2011).

Kriz tecrübeleri, bankaların finansal açıdan sorunlu hale gelmeden erken uyarı sistemleri ile izlenerek zamanında önlemler alınması ve bir şekilde sorunlu hale gelmiş bankalarda ise süre ve maliyet etkinliğini de sağlayacak şekilde çözümleme stratejilerinin uygulanması gereğini ortaya koymuştur (BDDK, 2009). Bu proaktif yaklaşımın en önemli ayağını finansal başarısızlığın belli bir süre öncesinden öngörülebilmesini temin edecek erken uyarı sistemleri oluşturmaktadır. Bu sistemler kullanılarak yapılacak doğru öngörüler ve zamanında alınabilecek tedbirlerle, finansal istikrar ortamının en az derecede etkilenmesi, yeniden yapılandırma maliyetlerini ortadan kaldırılması veya en azından azaltılabilmesi temin edilebilecektir.

Finansal başarısızlığın öngörülebilmesini sağlayacak bir erken uyarı sistemi kamu otoritelerinin yanı sıra, banka sahipleri, yatırımcılar ve bağımsız denetçiler gibi bir pek çok paydaşa katkı sunabilecektir. Erken uyarı sistemi; banka sahiplerinin gerekli önlemleri zamanında alabilmesine; yatırımcıların kaynaklarını daha iyi yönetebilmesine ve denetçilerin ise riskleri doğru bir şekilde öngörerek denetim risklerini yönetebilmelerine olanak sağlayacaktır. Bu özelliklerinden dolayı finansal başarısızlığın öngörülmesi günümüze kadar çok fazla araştırmacının ilgisini çekmiş ve bu alanda çok sayıda araştırma yapılmıştır.

Yapılan çalışmalar incelendiğinde, ilk olarak istatistiksel modellerin bu alana uygulanmaya başlandığı görülmektedir. İstatistiksel modellerin, normal dağılım ve bağımsız değişkenler arasında çoklu bağlantının bulunmaması gibi, çeşitli varsayımları bulunmaktadır. Bu varsayımların sağlanamadığının görülmesi ve zamanla yapay sinir ağları gibi akıllı tekniklerin gelişmesiyle bu teknikler daha fazla kullanılmaya başlanmıştır. Yapay sinir ağları modelleri yüksek öngörü başarısı göstermelerine rağmen modelin karar alma sürecinin yorumlanamaması nedeniyle eleştirilmiştir. Bu alana ilişkin ilginin de artmasıyla çok farklı analiz yöntemleri ile çok sayıda araştırma yapılmıştır. Çalışmalarda temel olarak finansal oranlar kullanılmakla

birlikte, nakit akışları, hisse senedi değerleri, volatilitesi gibi çok sayıda farklı veri türü de denenmiştir.

Bu çalışmada, 1997-2001 dönemi içerisinde faaliyet gösteren özel ticari bankalara ait finansal oranlar kullanılarak, finansal başarısızlığı öngören bir erken uyarı sistemi geliştirilmiştir. Sınıflandırma ve regresyon ağaçları yöntemiyle kurulan modelde, bankaların başarısızlığa uğrama durumlarının 1 yıl öncesinden öngörülmesine ve başarısızlığa uğrama nedenlerinin analiz edilmesine çalışılmıştır. Elde edilen sonuçlar daha önce bu alanda yapılmış çalışmalarla kıyaslanarak, seçilen yöntemin performansının değerlendirilmesi amaçlanmıştır.

Çalışma 3 ana bölümden oluşmaktadır. Birinci bölümde, yazın taraması sonucu elde edilen bilgilerle finansal başarısızlığın öngörülmesine ilişkin temel kavramlarla, bu alanda şimdiye dek kullanılan tahmin yöntemleri araştırılmış ve bu yöntemlerin avantajları ve dezavantajları irdelenmiştir. İkinci bölümde Kasım 200 ve Şubat 2001 krizlerinden kısaca bahsedilerek bu dönemlerde Türkiye'ye yerleşik bankaların finansal başarısızlıklarının öngörülmesine ilişkin yapılan çalışmalara yer verilmiştir. Üçüncü bölümde ise finansal başarısızlığın öngörülmesine yönelik ampirik bir çalışma gerçekleştirilerek kurulan modelden elde edilen bulgular sunulmuş ve ulaşılan sonuçlar yorumlanarak önceki çalışmalarla kıyaslanmıştır.

1. BÖLÜM

FİNANSAL BAŞARISIZLIĞIN ÖNGÖRÜLMESİ: TEMEL KAVRAMLAR VE TAHMİN YÖNTEMLERİ

Finansal başarısızlığın öngörülmesi yatırımcılar, kredi verenler, para ve sermaye piyasalarını düzenleyen kurumlar ve dış denetçiler gibi çok sayıda paydaşa sağladığı yararlar nedeniyle birçok araştırmacının ilgisini çeken bir konu olmuştur. 1960'lı yılların sonlarına doğru başlayan süreçte, günümüze kadar çok sayıda araştırma yapılmıştır. Kumar ve Ravi (2007) ile Demyanyk ve Hasan (2010) bu konuda günümüze kadar yapılan çalışmalara yönelik geniş inceleme çalışmaları sunmaktadırlar.

Konunun uygulamaya yönelik ciddi faydaları olmasına karşılık;

- tahmin etmede kullanılacak değişkenlerin seçimi,
- modelin fonksiyonel biçimi ve
- değişkenlere modellerde verilen ağırlıklar

konularındaki belirsizlikler, finansal başarısızlığı açıklamada bir mali kuram eksikliğinin bulunduğu şeklinde yorumlanmaktadır. Genel kabul görmüş böyle bir kuramın olmaması, farklı özelliklere sahip açıklayıcı modellerle tahmin yöntemlerinin ortaya çıkmasına yardımcı olmuştur. Bu konuda bir bilimsel kuram eksikliği kabul edilmekle birlikte, bu eksiklik finansal başarısızlığın öngörüsü alanında çalışmalar yapılmasının önüne geçememiştir. Çünkü yapılan çalışmaların gerekçesi, herhangi bir muhasebe kuramının tahmin gücünü ölçmekten ziyade uygulamaya dönük olarak herhangi bir işletmenin finansal başarısızlığının öngörülüp öngörülmeceğini araştırmaktır (R. Aktaş, 1997).

Günümüzde de halen popülerliğini koruyan bu alanda yapılan çalışmaları, bankalar ve diğer işletmeler üzerinde yapılanlar şeklinde iki ana gruba ayırmak mümkündür. Her iki grup üzerinde yapılan çalışmalar, kullanılan yöntemler ve temel kavramlar bakımından çok farklılık göstermediğinden literatür araştırması anlamında birlikte ele alınmaktadır.

Finansal başarısızlık kavramı, genel olarak bir işletmenin vadesi gelen borçlarını ödeyememesi, yasal olarak iflas süreci içerisine girmesi veya karşılıksız çek yazılması gibi çalışmalara ve kapsama göre değişen farklı kriterlerle tanımlanmıştır. Finansal başarısızlık, iflasa göre daha esnek bir terim olduğundan bu tür çalışmalarda tercih edilmiştir (R. Aktaş, 1997).

İflas durumunu da içeren finansal başarısızlık kavramı bankacılıkla ilgili yapılan çalışmalarda çoğunlukla bankacılık otoritesi tarafından bankaya el konularak yönetim ve denetiminin ilgili kamu kuruluşuna devredilmesi olarak kabul edilmiştir. Amerika özelinde yapılan çalışmalarda bankanın FDIC'ye, Türkiye'ye ilişkin çalışmalarda ise TMSF'ye devredilmesi finansal başarısızlığa uğrama durumunu ifade etmektedir.

Finansal başarısızlığın çok farklı nedenleri olmakla birlikte, yapılan çalışmalar genel olarak bankacılık sektöründeki başarısızlığın, ülke ekonomilerindeki makroekonomik yapının zayıf olduğu dönemlerde ortaya çıktığını göstermektedir. Özellikle, ekonomik büyümenin düşük, enflasyon ve reel faiz oranlarının yüksek olduğu, yetersiz yasal düzenlemelerin yanında doğrudan tasarruf mevduatı sigortasının uygulandığı ülkelerde riskin arttığı ifade edilmektedir. Finansal liberalleşme ile birlikte doğrudan tasarruf mevduatı sigortası uygulamalarının ahlaki çöküntü problemi yaratarak bankacılık sektöründe finansal başarısızlık olasılığını arttırdığı vurgulanmaktadır (Kılıç, 2006).

Diğer yandan, BDDK'ya göre TMSF'ye devredilen bankalardaki yoğun hâkim ortak suiistimleri, finansal başarısızlığa uğramada lisans verme sürecinin taşıdığı önemi gözler önüne sermiştir. Buna göre, lisans başvurularının değerlendirilmesi sürecinde; girişimcilerin nitelik ve niyetlerinin, riskleri yönetme kapasitesinin, içsel süreçlerinin ve kurumsal yönetim ilkelerinin titizlikle değerlendirilmemesi başarısızlık riskini arttırmaktadır (BDDK, 2009).

Bu çalışma kapsamında amaçlanan husus, bankaların finansal başarısızlığının öngörülmesi ve söz konusu başarısızlığa yol açan unsurların modelden edinilecek bilgilerle yorumlanabilmesi olduğu için daha çok tahmin modellerine yoğunlaşılacaktır.

1.1. MODEL KURMADA KULLANILAN GENEL METODOLOJİ

Tahmin, sınıflandırma ve tanımlama problemlerinin tamamında olduğu gibi finansal başarısızlığın öngörülmesine yönelik model kurmada izlenen genel metodolojiyi de 6 aşamada toplamak mümkündür (Maimon ve Rokach, 2010):

1. **Veri Toplama:** Uzman bilgilerinden yararlanılarak işe yarayabileceği düşünülen ve erişilebilen her türlü bilginin toplanarak bir veri seti oluşturulur. Bu aşamada model için gerekli olan bazı önemli verilerin elde edilememesi veya gözden kaçırılması durumunda model başarısızlığa uğrayacaktır.

2. Veri Ön İşleme: Eksik, gürültülü veya yanlış olduğu düşünülen veriler ele alınarak, veri temizliği sağlanarak verinin güvenilirliği arttırılmaya çalışılır.
3. Özellik Seçimi: Veri seti içerisinde yer alan fakat problemin çözümünde ilgisiz kalan veya gereğinden fazla olan özellikleri ayıklanır ya da bu özellikleri kullanarak problemin çözümüne fayda sağlayacak yeni özellikler bulunur.
4. Yöntem Seçimi: Bu aşamada, amaca uygun olarak tanımlama veya tahmin etmeye yönelik en uygun örüntü tanıma yöntemi seçilir.
5. Modelin Test Edilmesi: Belirlenen özellikler ve seçilen yöntem doğrultusunda oluşturulan model eldeki veri seti kullanılarak test edilir.
6. Modelin Değerlendirilmesi: Son olarak, modelin kurulmasındaki amaç doğrultusunda modelin güvenilirliği, kullanılabilirliği, tutarlılığı ve sonuçları yorumlanır.

İlerleyen bölümlerde finansal başarısızlığın öngörüsü yönelik kurulan modellerde bu aşamaların genel olarak nasıl ele alındığına ilişkin bilgiler sunulacaktır. Esas amaç tahmin yöntemleri üzerine odaklanmak olduğu için, diğer adımlardan kısaca bahsedilerek tahmin yöntemlerine geçilecektir.

1.2. FİNANSAL ORANLAR VE KULLANILAN DİĞER VERİLER

Finansal başarısızlığın öngörülmesine yönelik yapılan çalışmaların büyük çoğunluğunda işletmelerin finansal tablolarından elde edilen oranlar kullanılmaktadır. Halka açılan ve bu şekilde hisse senetleri borsalarda işlem gören işletmelerin finansal tablolarının kamuoyuna açıklanması zorunluluğu bu alanda yapılan çalışmalar için büyük bir veri kaynağı oluşmasını sağlamıştır.

Bankalar ise halka açık olmasalar dahi, kamu otoritelerince sıkı düzenlemelerle takip edilmekte ve 3 ayda bir yetkilendirilmiş bağımsız denetim şirketleri tarafından denetlenerek haklarında bağımsız denetim raporları hazırlanmaktadır. Bu raporlarda yer verilen finansal tablolar, bankaların finansal başarısızlığının öngörülmesi ve finansal verimliliklerinin değerlendirilmesi gibi birçok çalışmada kullanılmışlardır. İşletmelere nazaran daha sıkı düzenlemelere tabi tutulan ve denetlenen bankaların finansal tabloları bu tarz çalışmalar için daha güvenilir bir kaynak olarak değerlendirilmektedir.

Finansal oranların yanında, nakit akış bilgileri, hisse senedi değerleri, makro-ekonomik değişkenler, kurumsal yönetişime ilişkin kriterler veya denetçi değişimi gibi bazı farklı verilerde

çalışmalarda kullanılmıştır (Chen ve diğerleri, 2009; Cheng ve diğerleri, 2007). Bu verilerden bazılarının, finansal oranlarla birlikte değerlendirildiğinde kurulan modellerin öngörü gücünün artırılmasına ilave katkılarda buldukları da görülmüştür. Her ne kadar farklı veriler kullanılsa da finansal oranlar, başarısızlığın öngörüsünde tarihsel gelişimi de yansıtması anlamında vazgeçilmez bir unsur olarak görülmüş ve çalışmaların büyük çoğunluğuna temel teşkil etmiştir (Chen ve diğerleri, 2009).

Bu çalışmalarda ham finansal veriler veya muhasebe verileri yerine finansal oranlarla çalışılmasının en büyük yararı, işletme büyüklüğü endüstri ve risk sınıfı gibi modelde içerilmeyen niteliklerin kontrol altına alınarak etkilerinin azaltılmasıdır. Bir diğer yararı ise, parametre değerlerinin tahmininde uç gözlemlerin etkilerinin azaltılmasıdır (R. Aktaş, 1997).

1.2.1. CAMELS

Finansal oranlarla yapılacak böyle bir çalışmalarda önemli bir soru da hangi finansal oranlara model içerisinde yer verileceği olmaktadır. Finansal başarısızlığın öngörüsü alanında yapılan ilk çalışmalarda model içerisinde yer alacak finansal oranların sezgisel yöntemlerle belirlenmesi yolu tercih edilmişse de ilerleyen dönemlerde alana ilişkin uzman bilgisine ve yetkili otoritelerin karar alma aşamalarında göz önünde bulundurdıkları finansal oranlara doğru bir yöneliş olmuştur. Özellikle bankalara yönelik yapılan çalışmaların önemli bir kısmında CAMELS dereceleme sisteminde kullanılan oranların tercih edildiği görülmektedir.

CAMELS, orijinal adı ile Tekdüzen Finansal Kurumlar Dereceleme Sistemi (*The Uniform Financial Institutions Rating System – UFIRS*) Amerika Birleşik Devletleri’nde bankaların gözetim ve yerinde denetimi için kullanılan, başlangıçta 5 bileşen içerecek şekilde tasarlanan bir dereceleme sistemidir. İlk tasarlandığında Sermaye Yeterliliği (*Capital Adequacy*), Varlıklar Kalitesi (*Assets Quality*), Yönetim Yeterliliği (*Management Adequacy*), Gelirler (*Earnings*) ve Likidite (*Liquidity*) bileşenlerini içeren sisteme 1996 yılında “Piyasa Riskine Duyarlılık (*Sensitivity to Market Risk*)” bileşenin de eklenmesiyle bugünkü halini almıştır. Sistem, bileşenlerinin baş harflerinin bir araya getirilmesiyle oluşturulan CAMELS kısaltmasıyla anılmaktadır (Çinko ve Avcı, 2008). CAMELS başta Amerika olmak üzere, Hong Kong, İngiltere, Güney Kore, Şili, Arjantin ve Türkiye gibi birçok ülkede bankacılık sisteminin denetim ve gözetiminde ilgili otoriteler tarafından kullanılmaktadır (Kaya, 2001; BDDK, 2009).

CAMELS dereceleme sistemi oluşturulurken ilk olarak bankalar her bir bileşen için çeşitli finansal oranlar kullanılarak değerlendirilmekte ve 1-5 arası bir ölçek üzerinden derecelendirme yapılmaktadır. Buna göre “1” notu ilgili bileşende en iyi performans gösteren bankaları temsil ederken, artan notlar kötüleşen durumu ifade etmektedir. Her bir bileşen için 1-5 arası ölçekteki bu notlar hesaplandıktan sonra bileşenlerin ağırlıklı ortalaması o bankanın genel notunu vermektedir. Bu değerlendirme yapılırken ağırlıklar tamamen denetçinin kontrolünde olup; bankanın yapısı, büyüklüğü, genel ve/veya bankaya özel konular dikkate alınmaktadır. Bankaların hesaplanan CAMELS notu da yine 1 ila 5 arasında değişmektedir (Kaya, 2001).

CAMELS’ı meydana getiren bileşenler oluşturulurken aynı finansal oran birden fazla bileşende kullanılabilir. Örneğin bankaların varlık yapılarını değerlendirirken kullanılan finansal oranların bir kısmı aynı anda hem karlılığı, hem likiditeyi hem de varlık kalitesini etkileyebilmektedir (Kaya, 2001).

1.3. ÖZELLİK SEÇİMİ VE ÖZELLİK SEÇİM YÖNTEMLERİ

Veri seti içerisinde yer alan fakat problemin çözümünde ilgisiz kalan veya gereğinden fazla olan özellikleri ayıklamak ya da bu özellikleri kullanarak problemin çözümüne fayda sağlayacak yeni özelliklerin bulunması için kullanılan çok sayıda yöntem bulunmaktadır. Bunları üç ana başlık altında sınıflandırmak mümkündür: özellik seçimi, yapımı ve çıkarımı (Liu ve Motoda, 2008).

Özellik yapımı ve çıkarımı ile veri setinde yer alan özellikler kullanılarak onların birer fonksiyonları olan ‘bileşik’ özelliklerin elde edilmesi amaçlanır (Zhao ve diğerleri, 2009). Temelde birbirine yakın olan bu iki süreçten özellik yapımı, veri setindeki farklı özelliklerin kombinasyonlarıyla, özellikler arasındaki bilinmeyen bazı yeni ilişkilerin keşfedilmesini sağlamaya çalışmaktadır. Mesela 2 boyutlu bir problem için, genişlik ve boy bilgilerinin mantıksal operatörler kullanılarak tek boyutlu bir probleme dönüştürülmesi özellik yapımına örnek gösterilebilir (Liu ve Motoda, 2008).

Özellik çıkarımı ise, çok boyutlu özellik uzayının doğrusal veya doğrusal olmayan dönüşümlerle veri setindeki karakteristikler korunarak daha az boyutlu uzaylara dönüştürülmesi sürecini ifade etmektedir. A_1 ve A_2 ’nin gerçek veri setinde yer alan değerler olduğu bir durumda

$$B_1 = c_1A_1 + c_2A_2$$

olacak şekilde B_1 gibi yeni bir özellik türetilmesi bu sürece örnek gösterilebilir (Liu ve Motoda, 2008). Çok sayıda bilinen özellik çıkarımı yöntemi bulunmaktadır. Temel bileşen analizi (PCA), faktör analizi (FA) ve bağımsız bileşen analizi(ICA) özellik çıkarımı tekniklerinden en fazla bilinenleridir (Tsai, 2009).

Özellik seçimi ise, veri seti içerisinde yer alan ve gereğinden fazla veya problemin çözümüyle ilgisiz olan özelliklerin filtrelenmesi sürecini ifade etmektedir (Tsai, 2009). Özellik seçimi ile yeni özellikler oluşturulmaz, sadece elde var olan özellikler içerisinde seçim yapılır.

$$\begin{bmatrix} x_1 \\ x_2 \\ x_3 \\ x_4 \\ \vdots \end{bmatrix} \xrightarrow{\text{Özellik Seçimi}} \begin{bmatrix} x_1 \\ x_4 \\ \vdots \end{bmatrix} \quad \begin{bmatrix} x_1 \\ x_2 \\ x_3 \\ x_4 \\ \vdots \end{bmatrix} \xrightarrow{\text{Özellik Yapımı, Çıkarımı}} \begin{bmatrix} y_1 \\ y_2 \\ \vdots \end{bmatrix} = f \left(\begin{bmatrix} x_1 \\ x_2 \\ x_3 \\ x_4 \\ \vdots \end{bmatrix} \right)$$

Özellik seçimi ile filtreleme yapmanın 4 ana gerekçesi bulunmaktadır (Maimon ve Rokach, 2010):

1. Öğrenici modelin eğitim maliyetini düşürmek,
2. Modelin öğrenme performansını arttırmak,
3. Konuyla ilgisi olmayan boyutları azaltmak,
4. Gereğinden fazla olan boyutları azaltmak.

1.3.1. Doğru Özellikleri Bulmanın Önemi

Bankalarda finansal başarısızlığın öngörülmesine yönelik çok fazla sayıda çalışma yapılmış olmasına rağmen, birçoğunda özellik seçimine ilişkin hususlar dikkatli bir şekilde ele alınmamıştır. Halbuki konuyla ilgisi olmayan ve gereksiz özelliklerin modelin içine dahil edilmesi, modellerin daha fazla zaman tüketmelerine ve maliyetlerini arttırmalarına neden olurken, doğru öngörüle bulunma yüzdelerini de düşürmektedir (Tsai, 2009; Zhao ve diğerleri, 2009).

Bunlarla birlikte, özelliklerin kendileri arasındaki etkileşimleri de sınıflandırma problemlerinin performanslarının düşmesine sebep olabilmektedir. Özelliklerin etkileşimi; özelliklerin tek başına çok anlamlı sonuçlar vermediği durumlarda diğer özelliklerle birlikte değerlendirilmeleri sonucunda problemin çözümünde anlamlı sonuçlar vermesi olarak adlandırılabilir. Mesela bir

işletmenin ham muhasebe verilerinin finansal başarısızlığa ilişkin ipuçları vermediği durumlarda, likidite, karlılık ve büyüme oranı gibi oranlar finansal başarısızlığı açıklamada çok daha başarılı olabilmektedir (Zhao ve diğerleri, 2009). Bu anlamda özellik yapımı ve çıkarımı hususları da öngörü modellerinin performanslarını arttırmada ciddi bir rol üstlenebilmektedir.

Özellik uzayı boyutunun artması aynı zamanda öğrenici modelin öğrenme maliyeti diyebileceğimiz örneklem boyutunun da ciddi şekilde artmasını gerektirmektedir. Özellikle parametrik olmayan karar ağaçları gibi modellerde, özellik uzayı boyutunun artması durumunda, etkili bir öğrenme için gerekli örneklem uzayı üssel olarak artırılmalıdır (Rokach ve Maimon, 2008). Bu durum ise örneklem boyutunun oldukça küçük olduğu finansal başarısızlığın öngörülmesi problemlerinde ciddi bir sorun olarak görülmektedir.

Düşük boyutlarda etkin olarak çalışan, karar ağaçları gibi modeller, boyut ‘mütevazi’ bir büyüklüğü aştıktan sonra anlamlı sonuçlar üretememektedir. Bununla birlikte, az sayıda özellik içeren modeller sonucunda ortaya konan sonuçlar insanlar tarafından daha kolay anlaşılabilir (Rokach ve Maimon, 2008).

1.3.2. Özellik Seçimi Teknikleri, Filtre ve Sarmalayıcı Yaklaşım

Özellik seçimi algoritmaları özellik araması ve özellik alt küme değerlendirmesi olmak üzere iki ana bileşenden oluşmaktadır (Liu ve Motoda, 2008) .

Özellik arama algoritmaları sınıflandırma problemlerinin çözümünde oldukça fazla çalışılmış bir konudur. Optimum sonuca tüm seçenekleri kapsayacak 2^N (N veri setindeki özellik sayısı) alt kümenin değerlendirilmesi yoluyla ulaşılabilir, fakat bu çoğu zaman ve işlem yükleri açısından uygulanabilir olmamaktadır. Bunun için daha gerçekçi arama algoritmaları üzerinde oldukça çalışılmıştır. Bu algoritmalar içerisinde dizisel, rastsal ve bireysel arama algoritmaları sayılabilir (Liu ve Motoda, 2008).

Özellik değerlendirme sürecinde ise, her bir özellik veya özellik alt kümesi belirli bir kriter dahilinde değerlendirmeye tabi tutulur. Farklı değerlendirme kriterleri ile farklı seçimler yapılması olasıdır. Bu aşamada özellik değerlendirme sürecinde kullanılan metodun, sınıflandırma aşamasında kullanılan metodla aynı olması durumuna sarmalayıcı yaklaşım, farklı olması durumuna ise filtre yaklaşımı denilmektedir (Shin ve diğerleri, 2006).

Filtre yaklaşımında, sınıflandırıcı yöntemden bağımsız farklı bir yöntemle özelliklerin seçimi yapılmaktadır. Bu yaklaşımın en büyük avantajları, zaman ve hesaplama maliyetlerinin düşük olması, aşırı öğrenmenin (*over-fitting*) önüne geçebilmesi ve çok boyutlu özellik uzaylarını daha düşük boyutlara düşürebilmesidir (Li ve Sun, 2011).

Sarmalayıcı yaklaşımda ise, bizzat sınıflandırıcı yöntem özellik değerlendirme sürecinde de kullanıldığı için daha başarılı sonuçlar vermektedir. Fakat her bir özellik alt kümesinin sınıflandırma başarısının değerlendirilmesi gerektiğinden, zaman ve işlem yükü açısından maliyetli olmaktadır (Liu ve Motoda, 2008).

1.3.3. Finansal Başarısızlığın Öngörüsü Alanında Özellik Alt Kümesi Belirleme Yöntemleri

Finansal başarısızlığın öngörülmesi alanında kendini örgütleyen haritalar ve genetik algoritmalar gibi makine öğrenmesi yöntemlerini kullanarak özellik alt kümesinin belirlendiği çalışmalar olmakla birlikte, daha çok istatistiksel yöntemler olan t-testi, korelasyon matrisi, adımsal regresyon, temel bileşen analizi ve faktör analizi gibi yöntemler kullanılmıştır (Tsai, 2009).

Hangi yöntemlerin, finansal başarısızlığın öngörülmesinde daha başarılı sonuçlar verdiğine ve özellik alt kümesi belirleme yöntemlerinin sınıflandırıcıların performanslarını nasıl etkilediklerine yönelik de birçok çalışma yapılmıştır. Bunlardan birinde Tsai (2009), yukarıda sayılan istatistiksel yöntemlerin doğru sınıflandırma, Tip-I ve Tip-II hata oranlarını baz alarak birbirleriyle kıyaslamış ve t-testinin bu yöntemler içerisinde en başarılı sonuçları verdiğini, onu ikinci sırada adımsal regresyonun izlediğini ifade etmiştir.

Zhao, Sinha ve Ge (2009) ise finansal başarısızlık alanına ilişkin uzman bilgisi yardımıyla yapılan ‘özellik yapımı’ sürecinin sınıflandırma performansına olan etkisini ampirik bir çalışma ile test etmişlerdir. Çalışma sonucunda, özellik yapımı ile oluşturulan -finansal oranlar gibi- işlenmiş üst düzey özelliklerin, farklı yöntemlerle geliştirilen sınıflandırıcıların sınıflandırma performanslarını arttırdığı görülmüştür.

1.4. TİP-I VE TİP-II HATA

Finansal başarısızlık öngörüsü için kurulan bir modelin, finansal başarısızlığa uğramamış olan bir bankayı, finansal başarısızlığa uğramış bir banka olarak sınıflandırması Tip-I hata, finansal başarısızlığa uğramış bir bankayı, yanlış sınıflandırılması ise Tip-II hata olarak tanımlanmaktadır (Tsai, 2009).

		Gerçek Grup	
		<i>Başarısız</i>	<i>Başarısız Olmayan</i>
Tahmin Edilen Grup	<i>Başarısız</i>	Başarısız Doğru Tahmin (TN)	Tip-I Hata (FN)
	<i>Başarısız Olmayan</i>	Tip-II Hata (FP)	Başarısız Olmayan Doğru Tahmin(TP)

Tablo 1 Gerçek ve Tahmin Edilen Grup Sınıflandırma Tablosu

Finansal başarısızlık öngörüsü çalışmalarında kullanılan doğru sınıflandırma (*accuracy*), duyarlılık (*sensitivity*) ve belirlilik (*specificity*) oranları ise şu şekilde hesaplanmaktadır (Chaudhuri ve De, 2011):

$$\text{doğru sınıflandırma oranı} = \frac{TP + TN}{TP + TN + FP + FN} \times 100\%$$

$$\text{duyarlılık oranı} = \frac{TP}{TP + FN} \times 100\%$$

$$\text{belirlilik oranı} = \frac{TN}{TN + FP} \times 100\%$$

1.5. HATALI SINIFLANDIRMA MALİYETİ

Bankacılık sistemine yönelik kurulacak bir erken uyarı sisteminin özellikle I. ve II. tip hata maliyetleri açısından farklı şekilde değerlendirilmesinde yarar vardır. Erken uyarı sistemi tarafından finansal başarısız olarak öngörülen bir bankanın yakın takibe alınması ile gelecekteki olası bir finansal başarısızlık olayının önüne geçilebileceği açıktır. Bu durumda sistem, bankacılık sektöründe bir yeniden yapılandırma maliyetinden kaçınma olanağı sunacaktır (Kılıç, 2006).

Bir banka için erken uyarı sistemi tarafından gelecekte finansal başarısızlık yaşayacağı öngörülmemiş ancak başarısızlık gerçekleşmiş ise, bu durumda ek maliyet, bankanın yeniden yapılandırma maliyeti olacaktır (Tip-II hata maliyeti). Öte yandan, bir banka için gelecekte finansal başarısızlık öngörülmüş ancak gerçekleşmemiş ise, bu durumdaki ek maliyet, bankanın yakın takibe alınmasıyla ortaya çıkan denetim ve gözetim maliyetleri olacaktır (Tip-I hata maliyeti). Bu hata maliyetlerinin birbirlerine oranlarına bakıldığında Tip-II hata maliyetinin Tip-I hata maliyetine oranla çok daha fazla olacağı açıktır.

Daha önce de belirtildiği gibi, 2003 yılı itibariyle Türk bankacılık sektörünün yeniden yapılandırma maliyeti 47,2 milyar dolar olarak gerçekleşmiştir. Bu süreç içerisinde sadece TMSF'ye devredilen bankaların kamu maliyesi üzerine olan ek yükü 17,3 milyar doları (GSYİH'ya oranı %11,7) bulmuştur (BDDK, 2003). Dolayısıyla geliştirilecek bir erken uyarı sisteminde Tip-II hata oranı çok fazla önem ifade etmektedir.

1.6. ÖRNEKLEME YÖNTEMLERİ


Modellerin değerlendirilmesi konusunda izlenen standart yaklaşım genelde veri setinin belli bir kısmının eğitim (*training*) ve kalan kısmının ise modelin geçerliliğinin izlenmesi (*validation*) ve son olarak modelin test edilmesi (*testing*) şeklinde olmaktadır. Bu yöntem rastgele örneklem yöntemi olarak adlandırılırken, eğitim ve test setlerinin oranları çoğunlukla %60-%40 şeklinde belirlenmektedir. Yalnız özellikle finansal başarısızlık alanında veri setlerinin dar olması, kurulan modellerin bu kadar rahat bir şekilde eğitilmesine ve test edilmesine izin vermemektedir. Söz konusu durum, Türk bankacılık sektöründe yapılan finansal başarısızlığın öngörülmesine yönelik modellerin kurulması ve test edilmesinde de ciddi sorunlar teşkil etmektedir. Bu tarz küçük veri setleri ile çalışıldığında modellerin daha iyi test edilebilmesi için geliştirilen üç farklı yöntem bulunmaktadır (Pham, 2006).

1. Bir tanesini dışarıda bırakma (*Leave-one-out*): Bu yöntemde n tane gözlem içeren veri setinde, $(n-1)$ gözlem eğitim için, kalan gözlem ise test için kullanılmakta ve her bir seferinde farklı bir gözlemi test etmek üzere bu süreç n defa tekrarlanmaktadır.



Şekil 1 Bir tanesini dışarıda bırakma örnekleme yöntemi

2. k Bölmeli Çapraz Doğrulama Yöntemi (*k-fold cross-validation*): Bu yöntemde n gözlem içeren veri seti belirli bir sayıda gözlem içeren k tane bölüme ayrılmaktadır. Her bir defasında farklı olacak şekilde $(k-1)$ tane bölüm eğitim için kalan bölüm ise test için kullanılmaktadır. Bu yöntem küçük veri setleri ile gerçekleştirilen çalışmalarda oldukça popüler bir yaklaşımdır. k veri setinin boyutuna göre ayarlanabilmekle birlikte genelde 10 olarak belirlenmektedir.



Şekil 2 k bölmeli çapraz doğrulama örnekleme yöntemi

3. Bootstrap Yöntemi (*bootstrap method*): Bu yöntemde diğer yöntemlerden farklı olarak, bir gözlem birden fazla kez eğitim setinde yer alabilmektedir. n tane farklı gözlemin bulunduğu veri setinde, tekrar yerine koyma usulüyle rastgele seçilen ve dolayısıyla bir gözlemin birden fazla kez bulunabileceği n tane gözlem eğitim için kullanılırken, eğitim seti içerisinde yer almayan örnekler de test için kullanılmaktadır.

Bu süreç belirli bir döngü sayısınca tekrar edilerek, ortalama hata oranı tüm döngü sonuçlarının ortalaması alınarak tespit edilmeye çalışılmaktadır.

1.7. TAHMİN YÖNTEMLERİ

Kumar ve Ravi (2007)'ye göre finansal başarısızlıkların tahminine yönelik çalışmaları, kullanılan tahmin yöntemleri açısından değerlendirildiğinde;

- istatistiksel teknikler ve
- akıllı teknikler

olmak üzere iki başlık altında toplamak mümkündür. Bu sınıflandırmaya göre, istatistiksel teknikler başlığı altında; tek boyutlu modeller ile ayrıştırma analizi, regresyon analizi ve lojistik regresyon modellerini içeren çok boyutlu modeller ele alınırken, akıllı teknikler başlığı altında ise;

- yapay sinir ağları,
- karar ağaçları,
- durum tabanlı çıkarsama,
- genetik algoritmalar,
- kaba kümeler yaklaşımı,
- yöneylem araştırması,
- bulanık mantık, destek vektör makineleri ve diğer yöntemler,
- esnek hesaplama yöntemleri

sayılmaktadır.

Çalışmanın bu bölümünde ilgili teknikler hakkında çok kısa bilgilere yer verilirken, tekniklerin artıları ve eksileri üzerinde durulacak ve ilgili yöntemler kullanılarak yapılan çalışmalar irdelenecektir. Literatürde yer alan geçmişteki çalışmalara ilişkin özet bilgilere, çalışmada öne çıkarılan tekniğe ilişkin bölüm altında yer verilecektir.

1.7.1. İstatistiksel Teknikler

Finansal başarısızlığın tahmin edilmesine yönelik ilk çalışmalar istatistiksel yöntemler kullanılarak gerçekleştirilmiştir. İstatistiksel yöntemler, modelde kullanılan değişken sayılarına göre tek boyutlu veya çok boyutlu şeklinde ikiye ayrılabilir.

1.7.1.1. Tek Boyutlu Modeller

Tek boyutlu yaklaşımın iki temel varsayımı vardır:

- i. Finansal sıkıntı içindeki firmalara ait değişkenin istatistiksel dağılımı ile sıkıntı içinde bulunmayan firmalara ait değişkenin istatistiksel dağılımları birbirinden farklılık gösterir,
- ii. Bu sistematik farklılıklar finansal sıkıntıyı tahmin amacıyla kullanılabilir (Kılıç, 2006).

Tek boyutlu modeller uygulama kolaylığı açısından üstün olmakla birlikte; çelişkili sonuçların ortaya çıkması, önemli olabilecek bazı değişkenlerin önemsiz olarak algılanarak modele dahil edilmemesi gibi birçok dezavantajları barındırmaktadır (Aktaş ve diğerleri, 2003).

Bu modellerle ilk önemli çalışma William H. Beaver tarafından yapılmıştır. 1954–1964 yılları arasında finansal başarısızlığa uğramış 79 firmayı bire bir eşleme yöntemiyle 79 finansal başarısız olmayan firmayla eşleştirerek, 5 yıl öncesinden finansal başarısızlığı tahmin etmeye çalışmıştır. Bu çalışma içerisinde kullanılan “*nakit akışı/toplam borçlar*” oranıyla finansal başarısızlık durumu, önceki 5 yıl içerisinde %87 ila %76 arasında değişen doğruluk oranlarında tahmin edilebilmiştir (Beaver, 1966).

1.7.1.2. Çok Boyutlu Modeller

Ayrıştırma Analizi:

Ayrıştırma analizi grupların bazı bağımsız değişkenler için ortalamalarının birbirine eşit olup olmadığının test edildiği bir hipotezdir. Analiz için bağımsız değişkenler, ağırlıklar ile çarpılarak her bir gözlem için bir diskriminant değeri elde edilir. Her bir grup içinde yer alan gözlemlere ait diskriminant değerlerinin ortalaması alınarak grupların ortalaması bulunur. Elde edilen grup ortalamalarına “merkez” (centroid) denir ve grup sayısı kadar merkez hesaplanır. Grup ortalamaları o gruba ait herhangi bir gözlem için beklenen değeri gösterir (Çinko ve Avcı, 2008).

Ayrıştırma analizi hangi karakteristik özelliklerin gruplar arasındaki farklılığı ortaya çıkardıklarını ve ne kadar iyi ayırt edici olduklarını bulmak veya matematiksel modeller ortaya koyarak ayrıştırma işlemini sağlamak gibi farklı şekillerde kullanılabilir (Çinko ve Avcı, 2008).

Doğrusal ayrıştırma fonksiyonu, çoklu regresyon fonksiyonuna benzer şekilde aşağıdaki gibi ifade edilebilir.

$$Z_i = \beta_0 + \beta_1 x_{i1} + \beta_2 x_{i2} + \beta_3 x_{i3} + \dots + \beta_m x_{im}$$

Burada; Z_i : Ayrıştırma değerini,
 β_j : Ayrıştırma katsayılarını,
 x_j : Bağımsız değişkeni

göstermektedir (Aktaş ve diğerleri, 2003).

Bu yöntemle finansal başarısızlık tahmini alanında sınıflandırma yapılırken, söz konusu işletmenin Z değeri minimum hatayı sağlayan Z^* değeri ile karşılaştırılır ve eğer $Z > Z^*$ ise işletmenin finansal açıdan başarısız olmadığına, $Z < Z^*$ ise işletmenin finansal açıdan başarısız olduğuna karar verilir. Kopuş değerinden uzak olan Z değerlerinde doğru sınıflandırılma olasılığı daha yüksektir.

Bu yöntemin varsayımları şunlardır (R. Aktaş, 1997):

- Gruplar ayrık olup tanımlanabilir özelliğe sahiptir,
- Veriler yığından rassal örnekleme yöntemiyle çekilmiştir,
- Bağımsız değişken olarak alınan finansal oranlar çok boyutlu normal dağılıma sahiptir,
- Grupların sapma matrisleri birbirine eşittir.

Çok boyutlu ayrıştırma analizi finansal başarısızlık tahmini alanında ilk olarak Altman tarafından kullanılmıştır. Altman (1968) Z modeli olarak adlandırdığı modelinde, 1946-1965 yılları arasında imalat sektöründe yer alan finansal başarısızlığa uğramış 33 işletme ile bunlara eşlenik 33 finansal başarısız olmayan işletmeyi kullanarak, 22 finansal oran içerisinde iki grup arasında farkı ortaya koyan 5 finansal oran tespit etmiştir. Sonraki birçok çalışmada da kullanılan bu oranlar şunlardır:

1. Net işletme sermayesi / Toplam varlıklar
2. Dağıtılmamış karlar / Toplam varlıklar
3. Faiz ve vergi öncesi kar / Toplam varlıklar
4. İşletmenin piyasa değeri / Toplam borcun defter değeri

5. Satışlar / Toplam varlıklar

Altman, kurmuş olduğu modelle başarısızlıktan 1 yıl öncesi için %95, iki yıl öncesi için ise %72 oranında işletmeleri doğru sınıflandırmıştır (Altman, 1968).

Deakin (1972) ise Altman ve Beaver tarafından geliştirilen modelleri bir araya getirmeye çalıştığı araştırmasında, 1964-1970 yılları arasında başarısızlığa uğramış 32 işletme ile rastgele seçilen 32 başarılı olmayan işletmeyi analiz etmiştir. Deakin Beaver'ın modelini finansal başarısızlığı 5 yıl önceden tahmin etmede başarılı bulurken, Altman'ın modelinin ilk yıl için %95 oranında doğru sınıflandırmada bulunmasından faydalanmaya çalışmıştır.

Sinkey (1975) çok boyutlu ayrıştırma analizi kullandığı çalışmasında, 1969-1972 yıllarında Amerika'da ilgili kurum (FDIC) tarafından problem yaşayan bankalar sınıfına dahil edilen 110 banka ile problem yaşamayan 110 bankayı eşleştirmiş, 10 değişken kullanarak çoklu ayrıştırma analizi yapmış ve 1969'dan 1972'ye kadar ki dönemde yıllar içerisinde %35,91'den %24,76'ya düşen oranlarda yanlış sınıflandırma sonuçlarına ulaşmıştır.

Grice ve Ingram (2001) Altman'ın Z modelinin geliştirildiği yılları göz önünde bulundurarak, modelin halen geçerliliğini koruyup korumadığını ve imalat sektörü haricindeki sektörler için genelleştirilebilme durumunu test ettikleri çalışmalarında, Altman modelinin geçerliliğini kaybettiğini ve imalat sektörü haricindeki diğer sektörlerde uygulanmasının başarılı sonuçlar vermediğini tespit etmişlerdir. Bununla birlikte çalışmada Altman modelinin, finansal stres koşullarını tespit etmeye yönelik olarak kullanılabileceğini belirtmişlerdir.

Çoklu Regresyon Analizi (ÇRA):

Çoklu regresyon modelinin getirdiği çözüm klasik regresyondan farksızdır. Dolayısıyla bağımlı değişken olan finansal başarısızlık durumu ile bağımsız değişkenler olan finansal oranlar arasındaki ilişkiyi açıklamak da kolaydır. Modelde fonksiyon elde edildikten sonra sınıflandırma süreci ayrıştırma analizinde olduğu gibidir. Bu modelde de Z değeri 0-1 değerleri dışına taşabilmektedir (R. Aktaş, 1997).

ÇRA, ayrıştırma analizinden farklı olarak, grupların aynı yığından geldiğini varsayar, bu anlamda ayrıştırma analizi ÇRA'ya göre finansal başarısızlık alanında daha uygundur. ÇRA, finansal olarak başarılı-başarısız olma durumlarını aralıklı ölçek olarak kabul etmektedir. Başarılı olana 1, başarısız olan 0 değerini verirsek, bu aradaki gri alanın her iki duruma eşit

uzaklıkta olduğunu kabul etmek demektir. Halbuki, 0-1 arasındaki gri durum her iki tarafa eşit uzaklıkta değildir. Dolayısıyla finansal başarısızlığın derecesi aralıklı ölçek yerine, sıralama ölçeğiyle ölçülmelidir. Bu noktada da yine ayrıştırma analizi finansal başarısızlığın tahmini alanında daha uygun düşmektedir (R. Aktaş, 1997).

Meyer ve Pifer (1970) ÇRA kullanarak, 1948-1965 yılları arası verileri kullanarak 39 finansal başarısız ile 39 başarılı olmayan banka üzerinde gerçekleştirdikleri çalışmalarında, 1 ve 2 yıl öncesi için modelin yaklaşık %80 doğrulukla tahminde bulunduğu göstermişlerdir. Bu çalışmada başarısız olan ve olmayan bankaların aynı şehirden, aynı büyüklüklerde, aynı yaşam süresinde ve aynı denetim organlarına tabi olmasına dikkat etmişlerdir. Çalışma 2 yıldan daha uzun süreler için anlamlı sonuçlar vermemiştir.

Lojistik Regresyon ve Probit Modelleri:

Sosyal bilimlerde sıkça kullanılan regresyon analizi, bağımlı değişkenin nicel olmayıp nitel olması durumun da gerçekçi olmayan sonuçlar bulunmasına sebep olabilmektedir. Regresyon analizinde bağımsız değişkenlerin nitel veya nicel olması sorun yaratmazken, bağımlı değişkenin sürekli olduğu kabul edildiğinden, eksi sonsuz ve artı sonsuz arasında değerler alabilmektedir. Oysa finansal başarısızlık tahmini alanında da olduğu gibi sosyal bilimlerde bağımlı değişkenin nitel olduğu birçok durum söz konusudur (Çinko ve Avcı, 2008).

Lojistik regresyon modelinde bağımlı değişken Y'nin ikişerli ayrık olduğu varsayımı yapılır. Modelde bağımlı değişkenin 1 ile ifade edilen sonucu, yani olumlu olması ile ilgilenilmektedir. Y bağımlı değişkeninin k tane bağımsız değişkene bağımlı olduğu varsayımı yapılır. Bir diğer varsayım ise bağımsız değişkenlerin hiç birisinin bir başka bağımsız değişken ile tam bir doğrusal bağlantıya sahip olmadığıdır (Çinko ve Avcı, 2008).

Lojistik regresyon analizinin, çok değişkenli normal dağılım varsayımına ihtiyaç göstermemesi yöntemin bağıl bir üstünlüğü olarak görülmektedir. Yöntemin diğer bir üstünlüğü ise grup üyeliğine ilişkin olasılıkların belirlenebilmesidir. Lojistik regresyon modelinde normal dağılım yerine lojistik kümülatif yoğunluk dağılımı kullanılmaktadır (Benli, 2005).

Logit modelinde bir bankanın finansal başarısızlığa uğrama ihtimali (P_{L_a}), β 'nin model katsayıları ve F'nin finansal başarısızlığa ilişkin faktörleri (bağımsız değişkenleri) ifade ettiği durumda şu şekilde gösterilebilir:

$$P_{L_a} = \frac{1}{1 + e^{-(Z_{L_a})}}$$

$$Z_{L_a} = \beta_1 F_{1a} + \beta_2 F_{2a} + \dots + \beta_n F_{na}$$

Modelin parametrelerinin tahmini için en çok olabilirlik fonksiyonunun logaritması alınır ve sonrasında “Newton-Rapson tekrarlı tekniği” kullanılarak katsayılar hesaplanır. Olasılık değeri 0,5’ten büyük ise başarılı, küçükse başarısız grup içerisinde olduğu kabul edilir (Çinko ve Avcı, 2008). Bazı çalışmalarda ise sınıflandırma, Tip I ve Tip II tür hataları minimize edecek şekilde bir kesme değeri hesaplanmıştır (Canbas ve diğerleri, 2005).

Probit modelinde ise bir bankanın finansal başarısızlığa uğrama olasılığı (P_{P_a}) birikimli standart normal dağılım fonksiyonu olan:

$$P_{P_a} = \int_{-\infty}^{Z_{P_a}} \frac{1}{\sqrt{2\pi}} e^{-z^2/2} dz$$

$$Z_{P_a} = \beta_1 F_{1a} + \beta_2 F_{2a} + \dots + \beta_n F_{na}$$

şeklinde ifade edilir ve logit modeli ile aynı işlemler uygulanarak sonuca ulaşılır (Canbas ve diğerleri, 2005).

Finansal başarısızlık tahmini alanında lojistik regresyonla yapılmış en önemli çalışma Ohlson tarafından 1980’de yapılmıştır. Ohlson, daha öncesinde istatistiksel teknikler yardımıyla yapılan çalışmalarda, ilgili tekniklerin varsayımlarının sağlanamadığını ifade etmiş ve veri toplama konusunda eleştiriler getirmiştir. 1970-1976 dönemine ait verilerle 105 finansal başarısız 2058 finansal başarısız olmayan firma üzerinden gerçekleştirdiği çalışmasında ise başarısızlıktan önceki 1, 2 ve 3 üncü yıllar içerisinde sırasıyla %96,12; %95,55 ve %92,84 doğru sınıflandırma oranına ulaşmıştır (Ohlson, 1980).

Gentry, Whitford ve Newbold (1985) 1970-1981 yılları arasında finansal başarısızlığa uğrayan 33 işletme ile eşlenik fakat finansal başarısızlığa uğramamış 33 işletmeden oluşan veri seti üzerinde işletmelerin nakit akışlarını baz alarak, lojistik regresyon modelinden yararlanmışlardır. Kurdukları modelin 1 yıl öncesinde, %93 doğru üç yıl öncesi için %77 oranında doğru sınıflandırdığını göstermişlerdir.

1987 de ise yine aynı veri setiyle, fon akışlarının yanı sıra bazı finansal oranları da dahil ettikleri araştırmalarında, ayrıştırma analizi ile probit modelini kullanmışlar ve probit modeliyle ayrıştırma analizine göre daha iyi sonuçlar elde ettiklerini ifade etmişlerdir. Çalışmada nakit akışlarının, finansal oranlara nazaran daha iyi sonuçlar verdiği de belirtilmiştir (Gentry ve diğerleri, 1987).


İstatiksel yöntemlerin dezavantajları:

İstatiksel yöntemlerin en büyük dezavantajı bağımsız değişkenler olarak modellerde ele alınan finansal oranların normal dağıldığı varsayımdır. Yalnız yapılan çalışmalarda, finansal oranların normal dağılımdan daha çok sağa çarpık olduğu görülmüştür. Bu çalışmalardan birinde Deakin (1976), 11 finansal oran içerisinde “toplam borç/toplam varlık” oranının normal dağılım uyduğunu, ancak diğer 10 finansal oranın sağa çarpık dağılımlara sahip olduğunu göstermiştir. Finansal oranların normal dağılıma uymaması durumunda ortaya çıkan asimetrik dağılım, normal dağılım varsayımına dayalı olan gerek tek boyutlu gerekse de çok boyutlu modellerin kullanılmasında sorunlar ortaya çıkarmaktadır (R. Aktaş, 1997).

İstatiksel modellerde karşılaşılan diğer önemli bir sorun ise, finansal oranlar arasındaki korelasyondur. Bu durum, çoklu regresyon, logit ve probit modellerinde katsayıların standart hatasını etkilemekte ve bazı bağımsız değişkenlerin önemsiz gibi görülmesine neden olabilmektedir. Değişken seçiminin iyi yapılamaması ise kurulan modelin sadece kullanılan örneklem üzerinde başarılı sonuçlar vermesine neden olmaktadır (R. Aktaş, 1997).

1.7.2. Yapay Sinir Ağları

Temel olarak yapay sinir ağları (YSA) modelleri, insan beyninin çalışma prensiplerini ve öğrenme yeteneklerini taklit etmeye çalışan matematiksel modellerdir. Bir yapay sinir ağı, birbirleriyle bağlantılı homojen işlem birimlerinden oluşur. Sinir hücresi veya düğüm şeklinde isimlendirilen (neuron/node) işlem birimi i , diğer birimlerden sinyaller alır (x_i), bu sinyalleri bir giriş fonksiyonu içerisinde (S_i) ağırlıkları (w_i) ile birleştirerek, bir transfer (çıkış) fonksiyonunu (f) baz alarak çıktığı sinyali (o_i) üretir. Çıktı sinyali, ağıın topolojisine göre başka işlem birimlerine yönlendirilir. (Tam ve Kiang, 1992; R. Aktaş R. , 1997)



Şekil 3 Yapay sinir ağlarında düğüm (sinir hücresi)

Çıktıların hesaplanmasından sonra modelin öğrenme sürecine geçilir. Öğrenme yöntemleri temel olarak iki başlık altında ele alınabilir:

- i. Denetimli (supervised) öğrenme: Bu yöntemde yapay sinir ağına girdiler ve bu girdilerin sonucu olan çıktılar birlikte verilirler. Ağın görevi girdiler ile çıktılar arasındaki ilişkiyi öğrenerek modeli oluşturmaktır. Dolayısıyla denetimli öğrenme metodunun finansal başarısızlık alanında kullanılabilmesi için işletmenin başarısızlığa uğrayıp uğramadığı bilgisinin verilmesi gerekmektedir. Bu ise işletmelerin finansal başarısızlığa uğrama ihtimalleri bulunan dönemlerin geçilmesi ile mümkündür, dolayısıyla geçmişe yönelik bir bakış açısıyla gerçekleştirilebilmektedir. Geri yayılım algoritmasını kullanan ağlar bu sınıfa iyi bir örnek teşkil etmektedir (Lee ve diğerleri, 2005).
- ii. Denetimsiz (unsupervised) öğrenme: Bu yöntemde ağa sadece girdilerin verilmesi ağın eğitilmesi için yeterlidir. Dolayısıyla işletmenin başarısız olup olmadığı bilgisine ihtiyaç duyulmamaktadır. Denetimsiz öğrenen ağlar girdiler arasındaki ilişkileri öğrenerek çıktı olarak kullanıcı tarafından etiketlenilmesi gereken kümeler sunmaktadırlar. Kohonen tarafından geliştirilen SOM ağları bu yöntemde örnek olarak verilebilir (Lee ve diğerleri, 2005).

Yapay sinir ağları modelleri incelendiğinde, çok farklı modellerin finansal başarısızlık tahmininde bulunduğu görülmektedir. Ancak, bir denetimli öğrenme yöntemi olan geri yayılım algoritması (*back propagation*) ile çalıştırılan ileri beslemeli (*feed forward*) YSA modellerinin bu alanda en fazla kullanılan model olduğu anlaşılmaktadır (Çinko ve Avcı, 2008; Lee, Booth, ve Alam, 2005).

Denetimli öğrenen bir yapay sinir ağında bu süreç, bu ağırlık katsayıları olan w_i 'lerin sürekli değiştirilerek sonucun değerlendirilmesi şeklinde yapılmaktadır. Başlangıçta, ağırlıklar genelde -0.5 ile +0.5 arasında rastgele değerler olarak atanır ve bu ağırlıklarla çıktı değerleri hesaplanır. Hesaplanan çıktı değerleri ile olması gereken sonuçlar karşılaştırılır ve buna göre yeni ağırlık değerleri atanır. Her yeni örnek için aynı işlem tekrarlanır. Bu döngü, istenen çıktı değeri ile hesaplanan çıktı değeri arasındaki hata farkı, kabul edilebilir seviyenin altına düşene kadar devam edilir. Ağırlıkların nasıl yeniden atanacağını belirlemek üzere birçok farklı öğrenme algoritması geliştirilmiştir.

Yapay sinir ağlarını kullanan çalışmalar:

Tam ve Kiang (1992) doğrusal ayrıştırma analizi, lojistik regresyon, k-en yakın komşu algoritması, ID3 karar ağacı ile ileri beslemeli (net0) ve geri yayımlı 3 katmanlı (net10) sinir ağlarının performanslarını, 1985-1987 yılları arasında Texas'ta 59 finansal başarısızlığa uğramış ve varlık büyüklüğü, şube sayısı, kuruluş yılı (yaşı) ve statü bakımından eşleniği 59 finansal başarısızlığa uğramamış banka verisini kullanarak karşılaştırmıştır. 19 finansal oranın kullanıldığı çalışmada, 1 yıl öncesi için geri yayımlı (net10) sinir ağı (%85,2); 2 yıl öncesi için ise lojistik regresyon (%92,5) en başarılı sonuçları vermiştir. Çalışmada veri setinin belli bir oranı yerine test için ayırmak yerine (*hold-out*) 'bir tanesini dışarıda bırakma' (*leave-one-out*) yöntemini uygulandığında ise geri yayımlı (net10) sinir ağı hem 1 yıl öncesi için (%89,5), hem de 2 yıl öncesi için (%89,2) en başarılı sonuçları vermiştir.

Sharda ve Wilson (1993) 1975-1982 arasında 64 finansal başarısızlığa uğramış toplam 129 firma üzerinde Altman'ın modelinde kullandığı 5 değişkenle, 5 girdi, 10 gizli ve 2 çıktı düğümü olan yapay sinir ağı ile ayrıştırma analizinin başarısızlıktan 1 yıl önceki öngörü performanslarını karşılaştırmış ve geri yayımlı sinir ağının ayrıştırma analizine göre daha iyi sonuçlar verdiğini tespit etmiştir.

Benzer şekilde finansal başarısızlık alanında yapılan ve yapay sinir ağları ile ayrıştırma analizinin karşılaştırıldığı birçok çalışmada, yapay sinir ağlarının ayrıştırma analizine göre daha iyi sonuçlar verdiğine dair bulgulara ulaşılmıştır (Wilson ve Sharda, 1994; Leshno ve Spector, 1996).

Swicegood ve Clark (2001) Amerikan bankalarının raporlarından (*call reports*) elde edilen 1991-1992 yılları verileri ile ayrıştırma analizi, geri yayımlı yapay sinir ağı ve profesyonel insan yargısını kullanarak 1993 yılı için banka performanslarını öngörmeye çalışmışlardır.

Çalışmada finansal tablolardan elde edilen 17 değişken ile banka karakteristiklerine göre belirlenen 6 değişken kullanılmış, bankalar toplam varlıklarına göre (300 milyon dolar sınır) küçük (1000) veya büyük (741) bankalar olmak üzere iki sınıfa ayrılmıştır. Bağımlı değişken tarafında ise kar oranlarına göre her iki grupta %20'nin altında kalan bankalar düşük performans, %20'nin üzerindeki ise yeterli performans gösteren bankalar olarak belirlenmiştir. Ayırıştırma analizi, büyük ve küçük bankaları sırasıyla %86,4 ve %79,5, yapay sinir ağları ise %81,4 ve %78,25 oranlarında doğru sınıflandırırken yapay sinir ağları düşük performans gösteren bankaları öngörmeye diğer iki modelden daha başarılı sonuçlar üretmiştir.

Aktaş, Doğanay ve Yıldız (2003) Türkiye'de 1983-1997 yılları arasında İMKB'de işlem gören sanayi ticaret ve hizmet işletmeleri içerisinde 53'ü finansal başarısız toplam 106 işletmeye ait 23 finansal oranı kullanarak 1 yıl öncesinden finansal başarısızlığı için öngörmek için çoklu regresyon, ayırıştırma ve lojistik regresyon analizi ile yapay sinir ağlarını karşılaştırmışlardır. Çalışma sonucunda yapay sinir ağlarının doğru sınıflandırma oranının, istatistiksel metodlardan daha yüksek olduğu tespit edilmiştir.

Lee, Booth ve Alam (2005) tarafından yarısı finansal başarısız toplam 168 Kore firmasına ait veri seti üzerinde gerçekleştirilen çalışmada; denetimli öğrenen yapay sinir ağlarının, denetimsiz sinir ağlarına, ayırma ve lojistik regresyon analizine göre daha yüksek bir doğru sınıflandırma başarısı gösterdikleri sonucuna ulaşılmıştır.

Chen ve Du (2009) Tayvan'da halka açık işletmeler üzerinde yapay sinir ağları ve veri madenciliği (kümeleme) tekniklerinden k-en yakın komşu algoritmasını kullandığı çalışmada, geri yayımlı yapay sinir ağlarının finansal başarısızlığı öngörmeye daha başarılı sonuçlar verdiğini tespit etmiştir. Çalışmada ayrıca, finansal oranlar üzerinde faktör analizi uygulanmasının modelin öngörü başarısını düşürdüğü ve daha fazla Tip II hatasına neden olduğu sonucuna ulaşılmıştır.

Bunların haricinde finansal başarısızlığın öngörülmesinde geri yayımlı sinir ağları haricinde SOM ve PNN gibi farklı türlerde yapay sinir ağları kullanılarak gerçekleştirilen çalışmalarda mevcuttur (Lee, Han ve Kwon, 1996; Yang, Platt ve Platt, 1999).

Avantaj ve Dezavantajları:

Yapay sinir ağlarını istatistiksel yöntemlerden ayıran en önemli avantajları şu şekilde sıralanabilir:

1. Genelleme ve hata toleransı: YSA'nın öğrenme yeteneğinin sağladığı en büyük avantaj, eğitilmiş bir ağın eksik ve hatalı verilerle dahi doğru sonuçlara ulaşabilmesidir. Örneğin, insan yüzlerini tanıma konusunda eğitilmiş bir YSA, karanlıkta değişik açılardan çekilmiş fotoğraflarla kişileri doğru olarak tanıyabilmektedir. YSA'nın eksik bilgilerle de doğru sonuçlara ulaşabilme yetenekleri, geleneksel bilgisayar sistemlerinden farklı olarak hatalara karşı toleranslı olmalarına da neden olmaktadır (Aktaş ve diğerleri, 2003).
2. Herhangi bir varsayıma gerek duymaması: YSA istatistiksel modellerde olduğu gibi çeşitli varsayımlara ihtiyaç duymazlar. Bu özellik, istatistiksel varsayımların gerçekleşmesinin oldukça zor olduğu finansal başarısızlık alanında istatistiksel yöntemlere kıyasla sahip olduğu önemli bir avantajdır (Huang ve diğerleri, 2008) .
3. Uyum Gösterme: YSA'nın önemli özelliklerden birisi de, ağı eğitim dışında kullanım sürecinde de yeni durumları öğrenebilmesi ve uyum gösterebilmesidir (Aktaş ve diğerleri, 2003).
4. Paralel çalışma: Sinir ağındaki tüm işlem elemanları eş anlı olarak çalıştıkları için uygulama sürecinde de hızlı çözümler üretebilmektedir (Aktaş ve diğerleri, 2003).
5. Başarılı sonuçlar verme: Yapay sinir ağları, finansal başarısızlığın tahmininde diğer modellerle kıyaslandığı birçok çalışma sonucunda oldukça başarılı sonuçlar vermiştir. (Kumar ve Ravi, 2007)

YSA'nın yukarıda sayılan avantajları dışında bazı dezavantajları da bulunmaktadır. Bunlar:

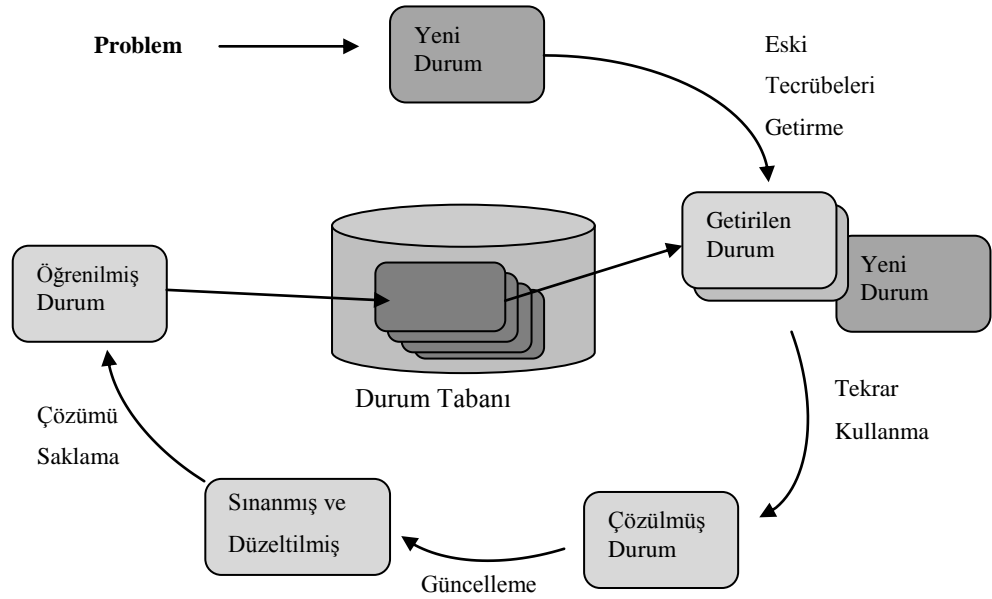
1. Uygun çözüme ulaşamama: Yapay sinir ağlarının her alanda uygulanabilir ve çözüm üretebilir bir özellik taşıdığını düşünmek yanlış olacaktır. YSA eğitim verilerinin yanlışlık veya eksikliğine bağlı olarak ilgisiz ve kabul edilemez sonuçlar üretebilmektedir. Bazı durumlarda ise ağı eğitimi mümkün olamamaktadır (Aktaş ve diğerleri, 2003).
2. Açıklama eksikliği: YSA'nın istatistiksel yöntemlere nazaran zayıf yönü sonuçlarının yorumlanabilir olmamasıdır. Örneğin finansal başarısızlık alanında; yapay sinir ağıyla kurulan modeller kapalı bir kutu olarak kalmakta, finansal başarısızlık konusunda hangi değişkenlerin önemli olduğuna dair bir bilgi modelden çıkartılamamaktadır (Aktaş ve diğerleri, 2003).
3. Geniş bir eğitim setine ihtiyaç duyması: Birçok yapay sinir ağı türü, kurulan modelin eğitilebilmesi için büyük bir eğitim setine veya fazla sayıda iterasyona ihtiyaç duymaktadır. Bu durum veri havuzu çok geniş olmayan finansal başarısızlık alanında önemli bir dezavantaj olarak kabul edilebilir (Kumar ve Ravi, 2007).

4. Katsayıların belirlenmesi için standart bir yöntem bulunmaması: YSA modelinde kullanılan öğrenme katsayısı, katman sayısı, hücre sayısı gibi birçok parametrenin nasıl belirlenmesi gerektiğine yönelik herhangi bir standart yöntem bulunmamaktadır. Bu durum, ağın en iyi sonuçları verebilmesi için gerekli parametrelerin bulunmasını zora sokan bir engeldir (Kumar ve Ravi, 2007).

1.7.3. Durum Tabanlı Çıkarsama

İnsanlar yeni bir problemle karşılaştıkları zaman problemi çözebilmek için, geçmiş tecrübelerinden elde ettikleri çözüm bilgilerini ya aynen kullanır veya duruma göre de bu bilgilerini revize ederek bir çözüm bulmaya çalışırlar. Durum tabanlı çıkarsama (DTÇ), insanların problem çözmede kullandıkları bu bilişsel sürece sezgisel olarak oldukça benzer şekilde işleyen bir yapay zeka dalıdır. (Kumar ve Ravi, 2007)

Bir çok yapay zeka teknolojisi, problem alanına ilişkin genel bilgilere dayanırken, DTÇ sadece geçmiş tecrübelerden yola çıkarak çıkarsamalarda bulunmaktadır. Bu yapısından dolayı karmaşık ve herhangi bir yapısalığı olmayan problemlerin çözümüne uygundur. Modelin bilgi veritabanını yeni durumlara uyarlamak da kolaydır. DTÇ'nin bu özellikleri, yönetim ve mühendislik alanlarında popüler olmasına neden olmuştur. DTÇ modelinin işleyişi aşağıdaki şekilde gösterilebilir: (Ahn ve Kim, 2009)



Şekil 4 Durum tabanlı çıkarsama yöntemi

Yukarıdaki döngüsel işleyiş içerisinde modelin performansı anlamında büyük ölçüde belirleyici olan en kritik adım, eski tecrübelerin getirilmesi aşamasıdır. Bu aşamada model, yeni durumu durum tabanı (eski tecrübeleriyle) ile karşılaştırarak yeni durumla en çok benzerlik içeren durumu belirlemeye çalışır. Bu metod “en yakın komşu eşleştirmesi” olarak adlandırılmaktadır (Ahn ve Kim, 2009).

Durum tabanında saklanan durumlar ile eldeki yeni problem arasındaki benzerliği ölçmenin çok fazla farklı yolu bulunmaktadır. Durumları özellikler vektörü olarak ifade ettikten sonra, özellikler arasındaki uzaklığın ağırlıklandırılmış toplamını almak uygulanan genel bir yaklaşımdır:

$$\frac{\sum_{i=1}^n W_i \times \text{sim}(f_i^1, f_i^R)}{\sum_{i=1}^n W_i}$$

W_i : i. özelliğin ağırlığını,

f_i^1 : i. özellik için yeni durumun değerini,

f_i^R : i. özellik için durum tabanından getirilen durumun değerini

$\text{sim}()$: benzerlik fonksiyonunu

ifade etmektedir. $\text{sim}()$ içerisinde genellikle öklit uzaklığı kullanılırken, farklı ölçütlerde kullanılabilir (Ahn ve Kim, 2009).

Avantaj ve Dezavantajları:

Durum tabanlı çıkarsamanın en önemli özelliği, geçmiş tecrübelerine dayanarak verdiği kararlar için bir açıklama verebilmesidir. Örneğin, DTÇ ile kurulan bir modelde işletmenin finansal başarısız olarak sınıflanması durumunda, model kararını haklı çıkarma adına geçmiş dönemlerde başarısız olan benzer işletmelerden örnek olarak gösterebilmektedir (Kumar ve Ravi, 2007).

DTÇ'nin kullanıcılar tarafından kolay anlaşılabilir olması, 'en yakın komşu sayısı' haricinde başka parametrelere ihtiyaç duymaması modelin üstün tarafları olarak sayılabilir.

DTÇ'nin en büyük dezavantajlarından birinin büyük çaplı veriler içeren problemlerin çözümünde kullanılamaması olduğu ifade edilmişse de, finansal başarısızlık tahmini gibi az sayıda örneğin bulunabildiği bir alanda bu dezavantajdan bahsetmek çok da olanaklı değildir (Kumar ve Ravi, 2007). Zaman içerisinde bilgisayar sistemlerinin de gelişmesiyle bu işlemsel yük de ciddi anlamda azalmış ve sorun olmaktan çıkmıştır (Ahn ve Kim, 2009).

DTÇ'nin sadece geçmiş tecrübelerden yola çıkarak çözümler üretmesi ve benzerlik fonksiyonuna olan bağımlılığı modelin zayıf yönlerini oluşturmaktadır (Berenji ve diğerleri, 2005).

DTÇ ile yapılan çalışmalar:

Bryant (1997) 1975-1984 yılları arasında, imalat ve perakende sektöründe yer alan 85'i finansal başarısızlığa uğramış toplam 185 işletme ile gerçekleştirdiği çalışmada durum temelli çıkarsama ve ile Ohlson'un (1980) lojistik regresyon modelini karşılaştırmıştır. Çalışma sonucunda Ohlson modeli, durum temelli çıkarsamaya göre doğru sınıflandırma ve Tip I hataları azaltması noktasında daha başarılı bulunurken, Tip II hata açısından daha kötü sonuçlar vermiştir.

Jo, Han ve Lee (1997) 1991-1993 yılları arasında 6 farklı sektörde faaliyet gösteren toplam 271 finansal başarısızlığa uğramış Kore firmasını yine aynı sektörlerde faaliyet gösteren finansal başarısızlığa uğramamış 271 firma ile eşleştirerek, yapay sinir ağları, durum temelli çıkarsama ve ayrıştırma analizi yöntemlerini kullanarak finansal başarısızlık öngörüsünde bulunmaya çalışmışlardır. *Stepwise selection* ve t-test kullanarak 20 finansal değişken seçilmiş, bir önceki

yılın verileri kullanılarak bir sonraki yılda finansal başarısızlığa uğrayan işletmeler öngörülme çalışılmıştır. 2 farklı değişken seçim yöntemi, 2 farklı önemlilik seviyesi, 3 farklı standardizasyon tipi ve 3 farklı eğitim/test bölümleri seçimiyle toplamda 36 farklı örneklem seti oluşturulmuştur. Yöntemlerin her bir örneklem setinde gösterdikleri ortalama doğru sınıflandırma oranları sonucunda, en başarılı yöntemin yapay sinir ağları olduğu, ayrıştırma analizinin durum temelli çıkarsamaya nazaran az da olsa daha iyi sonuçlar verdiği bulunmuştur (Jo ve diğerleri, 1997).

Li ve Sun (2008) ayrıştırma analizi ve lojistik regresyonu durum temelli çıkarsamanın farklı türevleri olan *Ranking Order CBR*, *Euclidean CBR*, *Manhattan CBR*, *Inductive CBR* yöntemleri ile karşılaştırmıştır. 2000-2005 yılları arasında Shanghai ve Shenzhen borsalarına kote 153'ü finansal başarısızlığa uğramış toplam 306 işletme verisi kullanılarak gerçekleştirilen çalışmada değişken seçimi için adımsal ayrıştırma analizi, logit ve ANOVA testi uygulanarak her bir metod için 3 farklı kombinasyon oluşturulmuştur. n-bölmeli çapraz doğrulama ile 30 farklı bölüm oluşturulan veri setinin her seferinde %70'i eğitim %30'u ise test için kullanılmış ve 30 farklı veri setiyle test edildikten sonra, sonuçların ortalamaları alınarak metodların öngörü başarıları ölçülmeye çalışılmıştır. Çalışma sonucunda değişken seçimi için adımsal ayrıştırma analizi kullanıldığı ROCBR metodunun daha düşük bir varyans ile en başarılı sonuçları ürettiği istatistiksel olarak da gösterilmiş, durum temelli çıkarsamanın değişken seçimine çok duyarlı olduğu ve doğru değişken seçim metodu kullanıldığında başarılı sonuçlar ürettiği ifade edilmiştir.

Li ve Sun (2011) yine aynı veri seti üzerinde benzer yöntemlerle yaptıkları başka bir çalışmada da ROCBR ile *forward feature selection*'in kombinasyonu ile oluşturdukları *forward ranking-order CBR* yönteminin, özellikle kısa dönem için ROCBR başta olmak üzere diğer CBR yöntemleri, destek vektör makineleri, ayrıştırma analizi ve lojistik regresyondan daha iyi sonuçlar verdiğini göstermişlerdir (Li ve Sun, 2011).

1.7.4. Karar Ağaçları

Karar ağaçları, yapay zekanın önemli bir alanı olan makine öğrenmesinin bir parçasını oluşturmaktadır. Karar ağaçları çoğunlukla sınıflandırma problemlerinde kullanılsa da, regresyon analizi amacıyla da işlev görebilmektedir (Maimon ve Rokach, 2010).

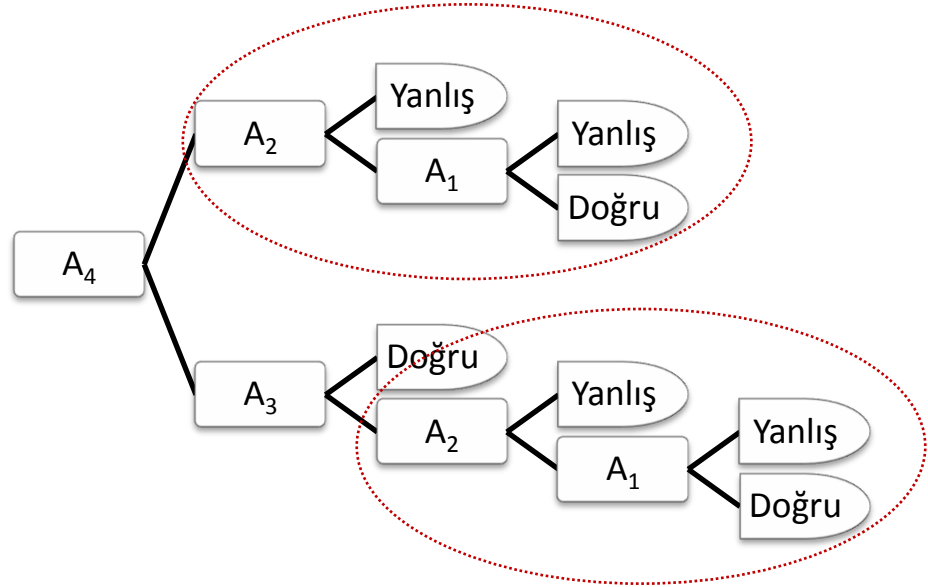
Karar ağaçları ile oluşturulan hiyerarşik yapı daha çok tersine çevrilmiş bir ağaca benzemektedir. Ağaç, kendisinden önce herhangi bir düğüm bulunmayan bir kök düğümle başlar. Kök düğüm haricindeki bütün düğümlerin bir öncül düğümünün olduğu ağaç yapısında, kendisinden sonra herhangi bir düğüm bulunmayanlara yaprak düğüm, bulunanlara ise iç düğüm adı verilir. Her bir iç düğüm, örnek uzayını, girdi olarak kabul edilen özelliklerin değerlerine göre iki veya daha fazla alana ayırır. Sınıflandırma ağaçlarında her bir yaprak bir sınıfa tayin edilmiştir. Sınıflandırılmak istenen her bir örnek, kök düğümden başlayarak yaprak düğüme ulaşıncaya kadar, girdi özellik değerlerine göre yönlendirilerek, ait olduğu sınıf tespit edilmeye çalışılır (Maimon ve Rokach, 2010).

Karar ağaçlarında öncelikle, ‘eğer-ise’ kuralları ile meydana getirilmiş ağaç yapıları oluşturulur. Bu oluşturulan kurallar; sonrasında problemin çözümü için kullanılır. Karar ağaçlarının oluşturulması için büyüme algoritmaları adları verilen ID3, CHAID, CART, Quest ve C5.0 gibi farklı yöntemler bulunmaktadır (Kumar ve Ravi, 2007).

Avantaj ve Dezavantajları:

Çözülme istenen bir problem için karar ağacı yapısını oluşturmak diğer modellere nispeten daha kolay ve zahmetsizdir. Özellikle çok fazla sayıda yaprak içermeyen ağaçların karar yapılarını yorumlamak kolaydır, dolayısıyla problemin çözümü için anlaşılabilir kurallar çıkarılabilmektedir. Girdi özellik değerleri içerisinde hem sürekli hem de ayrık değerler kullanılabilir. Eksik veriler içeren problemlerin çözümünde de kullanılabilen karar ağaçlarının herhangi bir parametreye ihtiyaç duymaması da güçlü yönlerinden biridir.

Bununla birlikte karar ağaçlarının eğitim setine oldukça duyarlı olması ve büyüme algoritmalarından bazılarının sadece sürekli verilerle çalışabilmesi yöntemin zayıf yönlerini oluşturmaktadır. Karar ağaçlarının “böl ve fethet” yapıda işlemesi problemin çözümünde çok etkili bir özellik olduğu zaman avantajlı olmakla birlikte kompleks bir etkileşim olduğunda dezavantaj olarak ortaya çıkmaktadır. Örnek vermek gerekirse, $y = (A_1 \cap A_2) \cup (A_3 \cap A_4)$ gibi bir fonksiyonu karar ağaçlarında oluşturmak için birbirlerinin kopyası olan bazı alt ağaçların ağaç yapısında oluşması gerektirmektedir. Aşağıdaki örnekte görüldüğü üzere A2 düğümünün altında kalan ağaç yapısı ağaç içerisinde tekrar etmektedir. Bu durum ağacın yapısının gereğinden fazla kompleks olmasına neden olmaktadır (Maimon ve Rokach, 2010).



Şekil 5 Kopya alt ağaçlar taşıyan bir ağaç yapısı

Karar ağaçlarıyla yapılan çalışmalar:

Marais, Patell ve Wolfson (1984) yinelemeli bölümlendirme algoritması olarak ifade edilen karar ağacı ile probit modellerini kullanmışlardır. Modellerin performansların tam olarak görebilmek için örnekleme yöntemi olarak bootstrap ile aynı veri setini hem eğitim hem test için kullandıkları yerine koyma yöntemini denemişlerdir. Halka açık olmayan işletmeler ile halka açık işletmelerin finansal tablolarının başarısızlık öngörüsü anlamında bir fark oluşturup oluşturmadığına da bakmak üzere 205 halka açık ve 716 halka açık olmayan işletme verisini kullanmışlardır. Halka açık olmayan işletmeler için 13'ü finansal oranlar olmak üzere 20 finansal veri değişken olarak alınırken, halka açık şirketler için 6 finansal olmayan değişken daha modele eklenmiştir. Yanlış sınıflandırılan işletmelerin, bankaya olan maliyetlerinin de standardize edilerek modele eklendiği çalışmada, kötü bir işletmeyi iyi olarak sınıflandırmanın maliyeti 1.00 alınırken, iyi olan bir işletmeyi kötü sınıflandırma maliyeti ise 0.33 olarak değerlendirilmiştir. Çalışma sonunda ulaşılan sonuçlardan biri, karar ağacı modelinin halka açık işletmeler için bootstrap örnekleme yönteminde probit modeline göre daha başarılı, yerine koyma yönteminde ise daha başarısız olduğudur (Marais ve diğerleri, 1984).

Frydman, Altman ve Kao (1985) 1971-1981 yılları arasında 58'i finansal başarısızlığa uğramış toplam 200 işletme üzerinde yaptıkları çalışmada ayrıştırma analizi ile karar ağacının öngörü performanslarını karşılaştırmışlardır. İki farklı ağaç modeli oluşturulan çalışmada, RPA1 modeli görece daha kompleks bir ağaç; RPA2 modeli ise en düşük çapraz doğrulama hatası veren ağaç olarak seçilmiştir. Karşılaştırma sonucunda, farklı hatalı sınıflandırma maliyetlerinin

tamamında RPA1 modeli ayrıştırma analizine ve RPA2 modeline göre daha başarılı bulunmuştur. Araştırmacılar karar ağaçlarının finansal başarısızlık alanında başarılı bir teknik olduğunu ve diğer prosedürlerle birlikte pratik bir karar aracı olarak kullanılabileceğini belirtmişlerdir.

1.7.5. Yöneylem Araştırması

Yöneylem araştırması (*Operations/Operational Research*); belirli kısıtlar altında bir problemin amaç fonksiyonunun optimize edilmesine yönelik olarak matematiksel modellerden oluşan bir yöntemdir. Yöneylem araştırmasındaki matematiksel modellerde, karar değişkenleri tam sayılı ya da sürekli olabilir, buna karşılık amaç fonksiyonları doğrusal olabilir ya da olmayabilir. Doğrusal programlama, Yöneylem araştırması içerisinde yer alan ve tüm amaç ve kısıt fonksiyonlarının doğrusal, değişkenlerin ise sürekli olduğu bir matematiksel tekniktir. Hemen hemen bütün yöneylem araştırma tekniklerinde, çözüme içerisinde yineleme (iterasyon) bulunan hesaplama algoritmalarıyla ulaşılır. Bu durum yöneylem araştırma tekniklerinde, yinelemeli algoritmalarından kaynaklanan çok sayıda işlem yükünün kaldırılabilmesi için bilgisayar sistemlerine başvurulmasını zorunlu kılmaktadır (Taha, 2000).

Yöneylem araştırması kapsamında kullanılan yaygın metodlardan olan veri zarflama analizi (VZA), doğrusal programlama teorisinin prensiplerine dayanan ve özellikle bir takım girdileri bir takım çıktılara dönüştürmekten sorumlu karar birimlerinin verimliliğini tahmin etmek için tasarlanmış parametresiz bir matematiksel bir programlama yöntemidir (Demir ve Astarcioglu, 2007).

VZA yöntemi, homojen oldukları varsayılan üretim birimlerini kendi aralarında mukayese etmektedir. Gerçekleşen en iyi gözlemin etkinlik sınırı olarak kabul edildiği yöntemde, diğer gözlemler bu etkin gözleme göre kıyas edilir. Uygulamada, her bankaya 0 ila 1 arasında bir etkinlik skoru verilerek örneklem içerisinde görece durumları değerlendirilmeye çalışılır (Fethi ve Pasiouras, 2010). Etkinlik sınırı gerçekleşmiş bir durumla tespit edildiği için, bu yöntemde rastsal hata kullanılmaz (Seyrek ve Ata, 2010).

Veri zarflama analiziyle; çoğunlukla banka verimliliğine etki eden unsurların araştırılmasında kullanılmıştır. Bu kapsamda, banka sahipliğinin, düzenleyici mevzuat değişikliklerinin, banka alımları veya birleşmelerinin verimliliğe olan etkileri üzerinde çok sayıda araştırmalar yapılmıştır (Fethi ve Pasiouras, 2010). Bununla birlikte veri zarflama analizi kullanılarak çıkarılan bankaya

ilişkin genel teknik verimliliğin finansal başarısızlıklarının öngörülmesinde kullanılabileceği de gösterilmiştir (Luo, 2003).

Avantaj ve Dezavantajları:

VZA'nın en iyi bilinen avantajı küçük örneklerle çalışabilmesidir. Diğer artıları ise, çok sayıda girdi ve çıktı kullanılmasına imkan tanınması, girdi ve çıktı arasında bir fonksiyonel ilişki kurulamak zorunda kalmaması ve homojen birimleri kendi aralarında kıyaslamasıdır.

VZA'nın en fazla öne çıkan sakıncaları ise,

- i. yöntemde rastsal hata kullanılmamasından dolayı, verilerdeki ölçüm hataları ve gürültüden fazlaca etkilenmesi,
- ii. mutlak bir verimlilik yerine göreceli bir verimlilik değeri üretmesi

olarak sayılabilir (Fethi ve Pasiouras, 2010; Demir ve Astarçioğlu, 2007).

Yapılan Çalışmalar:

Cielen, Peeters ve Vanhoof (2004) doğrusal programlama modeli, veri zarflama analizi ve karar ağaçlarını kullanarak 1994-1996 döneminde 90'ı başarısız toplam 366 banka üzerinde finansal başarısızlığı öngörmeye çalışmışlardır. Veri setinin Belçika Merkez Bankası'ndan temin edildiği ve her bir banka için 11 finansal oran kullanılarak gerçekleştirilen çalışmada veri zarflama analizi, doğrusal programlama modeli (MSD) ve karar ağaçları sırasıyla %86,4, %78,9 ve %85,5 oranında doğru tahminlerde bulunmuşlardır.

Kao ve Liu (2004) veri zarflama analizi ile 24 Tayvan bankası üzerinde gerçekleştirdikleri performans değerlemesi çalışmasında, geçmiş finansal oran ya da verileri kullanmak yerine, bankaların bazı finansal verilere ilişkin olarak kendi tahminlerini (aralık olmak kaydıyla) bir anket yordamıyla alarak gerçekleştirdikleri çalışmada iki bankanın verimlilik skorunu çok düşük bulmuşlardır. Söz konusu bankaların Asya finansal krizinde sıkıntı çektikleri görülmüştür.

1.7.6. Genetik Algoritmalar

Genetik algoritmalar (GA), ilk defa Michigan Üniversitesi'nde John Holland ve çalışma arkadaşları tarafından 1975'te geliştirilmiştir. Optimum sonucu bulmayı garanti etmeyen genetik algoritmalar, deterministik metodlarla çözüm bulmanın zor olduğu karmaşık arama uzayında en iyi çözümü bulmayı amaçlayan rastgele bir arama tekniğidir. GA optimal sonucu

garanti etmese de, genellikle optimal sonuca yakın değerler elde etmektedir. Bununla birlikte bütün uzayı taramadıklarından, hızlı sonuç üretebilme yeteneğine sahiptirler. (Er ve diğerleri, 2005; Kocamaz ve Çiçekli, 2010)

Genetik algoritmaları, geleneksel arama yöntemlerinden ayıran başlıca özellikleri (Shin ve Lee, 2002):

- i. arama uzayı üzerinde tek bir noktayı değil bir çok farklı noktayı göz önünde bulundurduğundan yerel optimum tuzağına düşme olasılığını azaltması,
- ii. parametrelerin kendileri ile değil parametre setlerini temsil eden karakter dizileri ile çalışması ve
- iii. arama sürecinde deterministik kuralları değil, olasılıksal kuralları kullanmasıdır.

Genetik algoritmalar, çözüm topluluğuna; seçim, çaprazlama ve mutasyon gibi genetik operatörler kullanılarak ulaşılmasını sağlarlar. Seçim operatörleriyle, popülasyon içerisinde uygunluk değerleri düşük olan bireylerin yerine yüksek olanların kopyalanmasını sağlar. Uygunluk değeri problemin amaç fonksiyonunun değerine eşittir. Çaprazlama ile iyi uygunluk değerlerine sahip iki bireyin iyi özelliklerinin birleştirilmesi ve bu şekilde daha iyi sonuçlar elde edilmesi amaçlanmaktadır. Bu aşamada hangi özelliklerin daha iyi sonuca yol açtığı bilinmediği için çaprazlama rastsal olarak gerçekleştirilmektedir. Mutasyon yoluyla da genlerden biri rastsal olarak değiştirilerek, çeşitlendirmeye gidilmektedir (Er ve diğerleri, 2005).

Avantaj ve Dezavantajları:

Genetik algoritmanın avantajlarından bir tanesi, problemin çözümüne ilişkin kuralları çıkartabilmesidir. Bir diğer güçlü yönü ise arama uzayından birden fazla noktayı aynı anda göz önünde bulundurmasından dolayı, yerel optimumda sıkışıp kalma olasılığının az olması ve arama uzayının büyük bir bölümünü gözlemleyerek başarılı bölgeler üzerine yoğunlaşabilmesidir (Shin ve Lee, 2002; Varetto, 1998).

Genetik algoritmaların, özellikle finansal başarısızlığın öngörülmesi için oluşturulan kuralların ve bu kuralların model içerisindeki kullanımının anlaşılabilir olması nedeniyle, yapay sinir ağları gibi karar alma süreçlerinin yorumlanamadığı yöntemlere nazaran bir üstünlüğü de bulunmaktadır (Shin ve Lee, 2002).

Genetik algoritmaların, çözüm setine ulaşmasının uzun zaman alması modelin en fazla değinilen negatif yönünü oluşturmaktadır. Bu sorun özellikle değerlendirmenin büyük ve kapsamlı

hesaplamalar gerektiği durumlarda öne çıkmaktadır. Bunun yanında, genetik algoritmanın uygun bir arama yöntemiyle yönlendirilmediği durumlarda global optimuma ulaşmasının garanti olmaması da yöntemin zayıf yanlarından biridir (Kumar ve Ravi, 2007).

Yapılan Çalışmalar:

Varetto (1998) 1982-1985 yılları arasında İtalya’da yer alan 1920 finansal başarısız ve 1920 finansal başarısız olmayan işletme verilerini kullanarak genetik algoritma ile lineer ayrıştırma analizinin öngörü performanslarını karşılaştırmıştır. Bir yıl öncesinden başarılı/başarısız işletmelerin sınıflandırılması ve 3 yıl öncesinde finansal başarısızlığa uğramayan işletmelerin öngörülmesinde ayrıştırma analizi daha başarılı bulunurken, 3 yıl öncesi dönemde başarısız işletmelerin tahmininde genetik algoritmanın (%92 > %90.1) daha iyi sonuçlar verdiği görülmüştür. Çalışma sonucunda ayrıştırma analizinin daha yüksek bir stabiliteye ve genelleştirme gücüne sahip olduğu ifade edilmiştir.

Shin ve Lee (2002), iki eşit gruptan oluşan ve 1995 – 1997 yıllarında Kore’de faaliyette bulunan, dış denetçilerin denetimine tabi orta ölçekli toplam 528 imalat işletmesine ait veriler üzerinde gerçekleştirdikleri çalışmada, iki aşamalı bir seçim süreci sonucunda istatistiksel olarak anlamlı bulunan 9 farklı finansal oranı kullanmışlardır. Veri setinin %90’ı eğitim, kalan kısmı ise modelin test edilmesi için ayrılmıştır. Başarısızlığa ilişkin 5 kuralın çıkartıldığı çalışmada, araştırmacılar tarafından örneklem üzerinde %80,8 oranında doğru sınıflandırma başarısı elde edilmiş ve genetik algoritmanın bu alanda kullanımının ümit verici olduğu ifade edilmiştir.

1.7.7. Kaba Kümeler

Kaba kümeler teorisi, Pawlak (1982) tarafından ortaya atılan ve belirli bir evrendeki her nesnenin sahip olduğu bazı bilgilerin var olduğu ve benzer bilgilere sahip nesnelere ayırt edilemeyeceği varsayımına dayanmaktadır. Kaba kümeler modelinde, bulanık kümelerin yerini alan alt ve üst yaklaşımlar, teoremin iki temel işlemini oluşturmaktadır. Alt yaklaşım belirli bir kümeye ait olduğu kesin bir şekilde bilinen nesnelere belirlerken, üst yaklaşım ise kümeye ait olması olası olan nesnelere kapsamaktadır.

Kaba kümeler, elde edilen verilerden sınıflandırma problemlerinin çözümü için karar kurallarının ortaya çıkarılmasında kullanılabilir. Bu kurallar alt yaklaşım veya üst yaklaşım için

sınıflandırma başarısı elde edilmiştir. Greco, Matarazzo ve Slowinski (1998) ise yine aynı veri seti üzerinde 4 bağımsız değişken kullanarak, %94,9 oranında doğru sınıflandırmada bulunmuş ve kaba kümeler üzerinde kullandıkları ‘dominance relation’ın ‘indiscernibility relation’dan daha üstün olduğunu göstermişlerdir.

McKee (2000) ABD’de halka açık şirketler üzerinde yaptığı çalışmasında finansal başarısızlığın öngörüsü için kaba kümeler yaklaşımını temel alan bir model gerçekleştirilmiştir. Modelin geliştirilmesi ve test edilmesi için farklı 100 şirkete ait finansal oranın bulunduğu veri seti kullanılmıştır. %88 oranında doğru sınıflandırma başarısı elde edilen çalışmada, aynı veri seti üzerinde karar ağaçlarına (%65) ve daha çok sayıda bağımsız değişken kullanılan önceki kaba kümeler modellerine göre daha yüksek doğru sınıflandırma oranına ulaşılmıştır.

McKee (2003) diğer bir çalışmasında ise 1991-1997 yılları arasında ABD’de faaliyet gösteren ve SEC’e kote olan 146’sı finansal başarısızlığa uğramış işletme ile bunların birebir eşlenmesi yöntemiyle oluşturulan toplam 291 işletme üzerinde, kaba kümeler yaklaşımı tahminleri ile denetçi öngörülerinin karşılaştırmasını gerçekleştirmiştir. Başarısızlık öngörüsünde (önceki çalışmalardan yola çıkarak) kullanılması muhtemelen 11 bağımsız değişken içerisinden dörder değişken seçilerek iki ayrı model oluşturulmuş, modeller %61 ve %68 oranlarında doğru sınıflandırmada bulunurken, denetçiler %66 oranını yakalamıştır. Çalışma sonunda, önceki çalışmaların aksine; kaba küme modellerinin, denetçilerin öngörüsüne ciddi katkılarda bulunamadıkları tespiti yapılmıştır. Araştırmacı bu sonucu, diğer çalışmalardan farklı olarak örneklem setinin daha gerçekçi olmasına bağlamıştır. Çalışmada finansal olmayan bazı değişkenlerin modele eklenmesinin ve kural setinin azaltılmasının sınıflandırma başarısını arttırabileceği öngörüsünde bulunulmuştur.

Cheng, Yeh ve Chiu (2007) 1998-2005 yılları arasında Tayvan’da finansal başarısızlığa uğrayan bire bir eşleme yöntemiyle oluşturulan 124 işletme (62’si başarısız) üzerinde yaptıkları çalışmada, 14 finansal oranın yanına son 3 yıl içerisinde denetçi değiştirip değiştirmediklerini (auditor switching) gösteren finansal olmayan bir değişkeni de eklemişlerdir. 6 farklı kaba küme modelinin gerçekleştirildiği çalışmada, finansal olmayan ‘denetçi değişimi’ değişkeninin, modellerin tahmin gücünü arttıran en önemli unsur olduğunu gözlemlemişlerdir.

1.7.8. Bulanık Mantık, Destek Vektör Makineleri Ve Diğer Yöntemler

1.7.8.1. Bulanık Mantık (Fuzzy Logic):

Bulanık mantık ilk olarak Lotfi A. Zadeh tarafından 1965'te ortaya atılmış; net olmayan ve belirsizlik içeren sezgisel terimlerin anlatımı üzerine kurulu matematiksel bir düzendir. Bulanık mantığın çıkış noktası klasik küme kuramındaki bir elemanın bir kümeye tam üyeliğine getirilen eleştiriler olmuştur. Klasik küme kuramında bir eleman herhangi bir kümeye ya üyedir ya da değildir. Bulanık mantıkta ise tam üyelik yerine, üyelik fonksiyonları kullanılarak; bir elemanın birden fazla kümeye belirli oranlarda üye olabilmesine yani kısmi üyeliğe imkan sağlanmaktadır (Yıldız ve Akkoç, 2009).

Bir bulanık uzman sistemi, dört temel aşamadan oluşur. Bu aşamalar kısaca şöyledir (Ballı ve diğerleri, 2009) :

- i. Bulanıklaştırma: Girdi değerleri belirlenen üyelik fonksiyonuna göre bulanık değerlere dönüştürülür. Bu aşamada 'düşük, orta, yüksek' gibi sözel değişkenlerle girdi değerleri ifade edilebilmektedir.
- ii. Bilgi Tabanı: Uygulama alanındaki uzman bilgisi ile oluşturulur. Girdi ve çıktı değerleri arasındaki ilişkiler bulanıklaştırılan girdi ve çıktı değerleri kullanılarak belirlenir.
- iii. Çıkarım: Uzman bilgisine dayalı kurallara göre eldeki bilgilerden çıkarım yapılır. Çıkarım aşamasında en fazla kullanılan çıkarım yöntemlerinden birisi Mamdani stili çıkarımdır.
- iv. Durulaştırma: Bulanık çıktı durulaştırılarak sayısal değere çevrilir. Bunun için en çok kullanılan yöntem ise 'ağırlıklı ortalama yöntemi'dir.

Bulanık mantık, klasik küme kuramına göre daha gerçekçi ve insanların bilişsel süreçlerine daha yakındır. Bulanık mantık, sözel değişkenler ve 'eğer-ise' şeklinde kuralları kullandıkları için sistemin karar alma mekanizmasının anlaşılması da oldukça kolaydır. Yalnız öğrenme yeteneklerinin olmaması, bulanık mantıkla tasarlanmış sistemlerin zayıf yönlerini oluşturmaktadır (Yıldız ve Akkoç, 2009). Bulanık mantığın dezavantajlarından biri de; üyelik fonksiyonları için çok fazla farklı seçenek olması ve olası bir yanlış üyelik veya durulaştırma fonksiyonu seçiminin, sonuçları ciddi şekilde çarpıtma ihtimalidir (Kumar ve Ravi, 2007).

1.7.8.2. Destek Vektör Makineleri:

Destek vektör makineleri (DVM), Vladimir Vapnik'in Yapısal Risk Minimizasyonu'nu esas alınarak önerilmiş olan, sınıflandırma, tanımlama, regresyon ve zaman serisi tekniğidir. DVM, temel olarak istatistiksel öğrenme teorisine dayanır ve girdi uzayını, ayrıştırmanın daha kolay olduğu çok boyutlu özellik uzayına dönüştürerek problemi çözmeye çalışır (Boyacıoğlu ve diğerleri, 2009).

DVM, temel olarak ikili bir sınıflandırma yöntemine göre tasarlanmışsa da çoklu sınıflandırma problemlerinde de uygulanmıştır. Finansal başarısızlığın öngörülmesi temel olarak ikili bir sınıflandırma gerektirdiği için DVM bu alanda rahatlıkla kullanılabilir. Girdi uzayını, çok boyutlu özellikler uzayına dönüştüren kernel fonksiyonu, sınıflandırma fonksiyonu setinin kompleksliğini belirlediği için DVM performansını da önemli oranda etkilemektedir (Boyacıoğlu ve diğerleri, 2009).

Uygun kernel fonksiyonu ve parametrelerinin seçiminin zor olması ve özellikle veri setinin büyük olduğu durumlarda optimum parametrelerin tespitinin oldukça zaman alıcı olması DVM'nin zayıf yönlerini oluşturmaktadır (Li ve Sun, 2008). Bununla birlikte, problem kuadratik programlamaya dönüştürüldüğü için global olmayan bir minimum olmaması, kuadratik programlama teknikleriyle çözülebilmesi ve az sayıda örneklem kullanılarak gerçekleştirilebilmesi gibi avantajlı olduğu konular da bulunmaktadır (Kumar ve Ravi, 2007).

Yapılan Çalışmalar:

Alam, Booth, Lee ve Thordarson (2000), bulanık kümeleme ve iki farklı SOM ağıyla yaptıkları çalışmada, ABD'de 1980-1992 yılları arasında finansal başarısızlığa uğramış bankalar içerisinde belli varsayımları sağlayacak şekilde oluşturdukları 100 bankalık veri setini kullanmışlardır. Araştırmacılar, veri setinde gerçek durumu yansıtacak oranda finansal başarısızlığa uğramış bankanın bulunması gerektiğini ifade etmişler ve bu oranın da yaklaşık %2 olduğunu göz önüne alarak, hazırladıkları sette rastgele seçtikleri 3 finansal başarısız bankayı dahil etmişlerdir. Çalışmada bankaları finansal başarısız/başarısız olmayan şekilde 2 katı kümeye indirgemekten ziyade gerçek hayattaki durumu yansıtacak bir örneklem setiyle, bankaların başarısızlığa uğrama potansiyelleri hakkında bilgi sunmak ve böylece karar alıcıların gerekli tedbirleri almasını sağlayabilmek amaçlanmıştır. Araştırmacılar önceki çalışmalardan esinlenerek 5 bağımsız değişken kullanmış ve bulanık kümeleme tekniği için bankaların başarı durumlarını değerlendirmek üzere 9 farklı kategori(küme) oluşturmuşlardır. Çalışma sonucunda hem

bulanık kümelemenin hem de SOM ağlarının finansal başarısızlığa uğrama potansiyeli olan bankaları öngörmede iyi teknikler olduğu kanaatine varılmıştır.

Min ve Lee (2005) Kore'nin en geniş kredi garanti organizasyonundan elde ettikleri 944'ü finansal başarısız ve toplam 1888 Kore firmasına ait veriler üzerinde yaptıkları çalışmada, optimum parametrelerini bulmak için grid araştırma tekniği ve örnekleme yöntemi olarak da 5-bölmeli çapraz doğrulama kullanmışlardır. Çalışmada, DVM'nin sınıflandırma başarısı, çoklu ayrıştırma analizi, lojistik regresyon ve 3 katmanlı geri yayılım algoritmasını kullanan yapay sinir ağlarıyla karşılaştırılmıştır. DVM, MDA ve Logit için verinin %80'nini eğitim %20'sini test amacıyla, Yapay sinir ağı için ise %60'ını eğitim, %20'sini doğrulama ve %20'sini de teste ayırmışlardır. Çalışma sonucunda, DVM'nin diğer yöntemlere nazaran daha başarılı sonuçlar elde ettiği görülmüştür.

Lanine ve Vennet (2006) parametrik bir model olan lojistik regresyon ve parametrik olmayan karakter algılama (trait recognition) modellerini Rus ticari bankalarının finansal başarısızlıklarının öngörüsü için kullanmışlardır. Karakter algılama yaklaşımını modifiye ederek kullandıkları çalışmalarında her iki model de eşik kriter değerini geçerken, modifiye karakter algılama modeli, lojistik regresyon ve modifiye edilmemiş karakter algılama modelinden daha iyi sonuçlar vermiştir. Çalışma sonucunda, likidite, varlık kalitesi ve sermaye yeterliliğinin bankaların finansal başarısızlığı konusunda belirleyici olduğu gözlemlenmiştir.

1.7.9. Esnek Hesaplama (Soft Computing)

Esnek hesaplama, bulanık mantık, yapay sinir ağları, genetik algoritmalar, makine öğrenmesi ve kaba kümeler teorisi gibi; birbirinden farklı yapay zeka teknolojilerinin güçlü yönlerini bir araya getirerek entegre bir sistem oluşturulması paradigmasıdır. Bu terim, 1990'lı yılların başında Zadeh tarafından türetilmiştir ve son dönemlerde finansal başarısızlığın öngörülmesinde oldukça popüler bir yöntem olarak değerlendirilmektedir (Demyanyk ve Hasan, 2010). Esnek hesaplama, insan beyninin bilişsel sürecini bir rol model olarak kabul edip, matematiksel formülasyonlarla bu süreci modellemeye çalışmaktadır. Bu paradigma içerisinde, farklı yapay zeka teknolojilerinin melezleştirilerek kullanılması, bunların birbirleriyle rekabet eden değil, birbirlerini tamamlayan teknikler olarak görülmesi nedeniyledir. Melez mimariler, tekniklerin doğasında var olan bazı dezavantajları minimize ederken, tekniklerin güçlü yönlerini bir araya getirerek maksimize etmektedir. Kullanılan bazı esnek hesaplama tekniklerini; sinirsel-bulanık,

bulanık-sinirsel, sinirsel-genetik, genetik-bulanık, sinirsel-bulanık-genetik, kaba küme-sinirsel, vd. olarak saymak mümkündür. Ayrıca çoklu sınıflandırma sistemleri ve grup (*ensemble*) sınıflandırma yöntemleri de esnek hesaplama sistemleri olarak görülmektedir (Kumar ve Ravi, 2007).

Esnek hesaplama ile finansal başarısızlık öngörüsü alanında yapılan çalışmalar üç ayrı başlık altında ele alınabilir (Kumar ve Ravi, 2007):

- i. Grup (*Ensemble*) Sınıflandırma yaklaşımında, her bir teknik kendi başına tahminlerde bulduktan sonra, bir arabulucunun yönetiminde ağırlıklandırılmış/salt çoğunluk esaslı oylama yöntemleri veya tahminlerin lineer bir kombinasyonu ile öngörülerde bulunmaya çalışılır.
- ii. Diğer bir yöntem, özellik alt kümelerinin belirlenmesinde ve tahminlerde bulunmak için farklı yapay zeka tekniklerinin melez olarak kullanılmasıdır. Bu yöntemde, özellik alt kümesinin belirlenmesi için kullanılan tekniğin seçtiği özellikler tahminleme için kullanılan tekniğe girdi olarak kabul edilirler.
- iii. Son yaklaşım olarak da, genetik algoritmalarla eğitilen yapay sinir ağları ya da sinirsel bulanık ağlar gibi birbirlerine sıkı bir şekilde entegre olmuş sistemler kullanılması gösterilebilir.

Yapılan Çalışmalar:

Huang, Tsai, Yen ve Cheng (2008) statik ve trend analiz modellerini geri yayımlı bir yapay sinir ağının eğitilmesinde kullanarak oluşturdukları melez modelin performansını, Tayvan'da finansal başarısızlığa uğrayan işletmelere ait veriler üzerinde, ayrıştırma analizi, karar ağaçları, C5.0 karar ağacı ve geri yayımlı sinir ağıyla karşılaştırmışlardır. Melez model, finansal başarısızlığa uğrayan işletmelerin doğru sınıflandırılması bakımından diğer modellerden daha başarılı bulunmuştur.

Nguyen, Shi ve Quek (2008) geliştirdikleri Ying-Yang Fuzzy CMAC modeli ile 1980-2000 yılları arasında 702'si finansal başarısızlığa uğramış toplam 3635 ABD bankasına ait bankasına veriler üzerinde finansal başarısızlık tahmininde bulunmuşlardır. 9 bağımsız değişkenle, veri setinin %80'i eğitim %20'si test için kullanılırken, 5-bölmeli çapraz doğrulama sonrası sonuçlar değerlendirilmiştir. Çalışmada finansal başarısızlığa uğrayan bankalara ait ulaşılan son verilerin kullanılmasıyla %95, bir yıl önceki verilerin kullanılması ile %85 ve 2 yıl önceki verilerin kullanılması ile %75 oranında finansal başarısızlığa uğrayan bankaların tespit edilebildiği görülmüştür.

Ahn ve Kim (2009) ağır sanayi sektöründe yer alan ve 1996-2000 yılları arasında finansal başarısızlığa uğrayan 1335 işletme ile aynı sektörde fakat 1999-2000 yılları arasında finansal başarısızlığa uğramamış olan toplam 2670 işletmeyi ele almışlardır. Veri seti üzerinde, 111 değişken içinden t-test, lojistik regresyon analizi ve kredi verme konusunda yetkili uzmanların görüşlerine dayanarak 15 değişken seçilmiştir. Çalışma sonucunda genetik algoritma ve CBR melezinin (GOCBR) diğer CBR modellerinden daha iyi bir başarı gösterdiği McNemar ve iki örneklem testleriyle görülmüştür. Genellikle daha düşük bir performans sergileyen durum temelli çıkarsamanın, genetik algoritmalar yardımıyla en az yapay sinir ağı kadar isabetli sonuçlar verebildiği de istatistiksel olarak gösterilmiştir.

Chen, Huang ve Lin (2009) 1998-2002 yılları arasında SEC'e kote olan firmaların finansal başarısızlıklarının tahmininde sinirsel bulanık ağ modelini kullanmıştır. Çalışmada büyüklük, sektör ve süreçler dikkate alınarak 100 finansal başarısız uğramış işletme ile 100 sağlıklı işletme eşleştirilmiş, veri setinin %70'i eğitim, %30'u ise test için kullanılmıştır. Bağımsız değişken seçiminde faktör analizi uygulanarak 6 bağımsız değişken belirlenirken, Tip II tür hataların maliyetlerinin Tip I tür hatalara oranla daha fazla olduğu kabul edilmiştir. Bu sonuçtan yola çıkarak, yanlış sınıflandırma maliyetlerinin hesaplanmasında Tip II hatalarının maliyetleri için Tip I'in 50, 100, 200, 500 ve 1000 katı için modeller ayrı ayrı değerlendirilmiştir. Çalışma sonucu modeller; (i) doğru sınıflandırma başarısı, (ii) yanlış sınıflandırma maliyeti ve (iii) finansal başarısızlığı tespit etme başarısı olmak üzere üç başlık altında değerlendirilmiştir. Doğru sınıflandırma ve yanlış sınıflandırma maliyetinin düşüklüğü açısından sinirsel bulanık ağ modeli, yapay sinir ağı ve logitten daha başarılı sonuçlar vermiştir. Araştırmacılar, finansal durumun değerlendirilmesinde likidite oranlarının önemli olduğunu tespit etmişlerdir.

Andrés, Lorca, Juez ve Sánchez-Lasheras (2011) 2007 yılında finansal başarısızlığa uğramış 138 ve finansal başarısızlığa uğramamış 59.336 İspanyol işletmesi üzerinde gerçekleştirdikleri çalışmada bulanık kümeleme ve *Multivariate Adaptive Regression Splines* (MARS) kombinasyonundan oluşan melez bir model ortaya koymuşlardır. (Altman, 1968) çalışmasında yer alan 5 finansal oranın bağımsız değişken olarak alındığı çalışmada melez model, geri yayımlı yapay sinir ağları, ayrıştırma analizi ve MARS modellerinden daha başarılı sonuçlar üretmiştir. Yazarlar MARS ve bulanık kümeleme melez modelinin finansal başarısızlık alanında uygulanabilir bir model olduğunu belirtmişlerdir.

Li ve Sun (2011) Çin’de halka açık işletmeler üzerinde yaptıkları çalışmada, temel bileşen analizi ile melezleştirmenin ayrıştırma analizi ve lojistik regresyon analizinin kısa dönemli öngörü performansını iyileştirdiğini göstermişlerdir. Çalışmada adımsal ayrıştırma analizi, adımsal lojistik regresyon ve t-testi özellik seçimi için kullanılmış, seçilen özellikler üzerinden temel bileşen analizi yapılarak, ayrıştırma analizi ve lojistik regresyon modellerine girdi olarak kullanılmıştır.

2. BÖLÜM

TÜRKİYE’DE YERLEŞİK BANKALAR HAKKINDA ÇALIŞMALAR

Bu başlık altında öncelikle Türkiye’de bankacılık sektöründe yaşanan finansal başarısızlıkların önemli bir kısmını tetikleyen Kasım 2000 ve Şubat 2001 krizlerine ve sonrasında Türk bankacılık sektörüne yönelik yapılan araştırmalara değinilecektir. Kasım ve Şubat krizleri banka finansal başarısızlıklarının hangi ekonomik koşullar altında gerçekleştiğinin anlaşılabilmesi ve finansal başarısızlıkları tetikleyen unsurların irdelenebilmesi açısından önem ifade etmektedir.

2.1. KASIM 2000 VE ŞUBAT 2001 KRİZLERİ

Türkiye uygulamaya konulan istikrar programlarının çeşitli nedenlerle sonuçlandıramaması nedeniyle 1990’lı yıllardan itibaren sıklaşan aralıklarla krizlerle karşı karşıya kalmış, ekonomideki kırılganlıklar giderek artmıştır. Bu dönemde bankacılık sektöründe makro ekonomik istikrarsızlık, kamu bankalarının bozucu etkisi, sektördeki küçük ve parçalı yapı, risk yönetimi konusundaki eksiklikler gibi temel yapısal sorunlar, 2001 yılı Şubat ayında yaşanan döviz kuru krizinin derinleşerek sistemik bankacılık krizine dönüşmesine neden olmuştur (BDDK, 2009).

Finansal kriz ilk olarak 22 Kasım 2000’de kendini hissettirdi. 13 Kasım’dan itibaren yükselmeye başlayan bankalararası piyasada gecelik borçlanma basit faizi bu tarihte yaklaşık üç kat artarak ortalama %110.8’e, en yüksek %210’a fırladı. Faiz sonraki günlerde düşmüş ve Ağustos, Eylül ve Ekim aylarda böyle bir sıçrama olmamasına rağmen yaşanan bu durum kamu kesimi maaş ödemesine bağlanmıştı (Uygur, 2001).

22 Kasım’da ve izleyen günlerde Merkez Bankasının döviz rezervinde önemli bir azalma gerçekleşti. TCMB, dövizde hedef alan yoğun spekülasyon saldırıyı çok yüksek faiz, önemli döviz rezervi kayıplarıyla ve 7.5 milyar dolar büyüklüğündeki ek rezerv olanağı (SRF) şeklinde sunulan maliyetli IMF kredisi ile geri püskürtebilmişti. İlan edilen döviz kuru çizelgesini yüksek maliyetine rağmen savunan TCMB daha sonra olabilecek benzer bir saldırıya karşı savunma gücünü büyük ölçüde kaybetmişti (Uygur, 2001).

IMF ile yapılan program gereği, yapısal uyum sürecinde en önemli konulardan biri, riskli olduğu bilinen bankacılık kesiminin yeniden yapılandırılmasıydı. Ancak, yeniden yapılandırma girişimlerinde TMSF bünyesine yeni bankalar eklendikçe, riskli banka sayısının çok daha

yüksek olduğu ve sistemin sanıldığından da zor durumda olduğu duygusu piyasalara hakim oldu. Üstelik, bankacılık sektöründe en azından döviz ve vade uyumsuzluklarına karşı denetlemek üzere konulan bazı kuralların da uygulanamadığı bizzat TCMB kaynaklı açıklamalardan bilinmekteydi (Uygur, 2001).

Bankacılık kesiminin 2000 Eylül ayı sonunda bilanço döviz açık pozisyonu değer olarak 20.95 milyar dolara, oran olarak %205'e varmıştı. Açık pozisyon oranı kural olarak konulan %20 oranının tam 10 katını bulmuştu. Yasaya rağmen Bankalar döviz borçlarının riskini döviz forward kontratlarıyla karşıladıklarını söyleyip bu kontratları da bilanço dışı nazım hesaplarda rapor etmekteydiler. Ancak forward kontratlar yerli ve/veya holding firmalarıyla yapılmakta ve gerçekte döviz borçlarının ancak çok küçük bir bölümünü karşılamaktaydı. Haliyle, bankaların önemli döviz riski taşıdıkları özellikle dış borç veren yabancı kuruluşlar tarafından bilinmekteydi (Uygur, 2001).

Kasım krizinin aşılmasından tam üç ay sonra 19 Şubat 2001'de yaşanan siyasi bir gerginlik, ikinci bir spekülasyon saldırısını başlattı ve bu kez döviz krizi başladı. 21 Şubat'ta bankalararası para piyasasında gecelik faiz %6200'lere kadar çıkarken ve ortalama olarak %4018'i buldu. Şubat krizinde Merkez Bankası döviz rezervi 22,6 milyar dolara indi ve rezerv kaybı 5,4 milyar dolar oldu. Şubat krizinde yerlilerin özellikle de bankaların dövizde saldırdığı görüldü. Dövizde yapılan saldırıya dayanma gücü kalmayınca, TCMB 21 Şubat gecesi kurun dalgalanmaya bırakıldığını açıkladı ve on gün içinde dolar kurundaki artış %40'a ulaştı (Uygur, 2001). Bu durum, faize ve döviz kuruna aşırı derecede duyarlı olan bankacılık kesiminde ağır tahribatlar yaptı ve ciddi bir güvensizlik ortamı oluşmasına neden oldu.

Sonunda, krizlerin etkisiyle mali bünyeleri iyice bozulan bankaları sağlıklı bir yapıya kavuşturabilmek amacıyla, 2001 yılı Mayıs ayında "Bankacılık Sektörü Yeniden Yapılandırma Programı" uygulamaya konuldu. Program ile kamu bankalarının yeniden yapılandırılması, TMSF'ye devredilen bankaların çözümlenmesi, özel bankacılık sisteminin rehabilitasyonu, gözetim ve denetim çerçevesinin güçlendirilmesi ve sektörde etkinliğin artırılması amaçlanmıştı (BDDK, 2009). Yaşanan devirlerle birlikte, bankacılık sektörünün yeniden yapılandırılmasının kamu maliyesine getirdiği ek yük 39,3 milyar dolar, bunun GSYİH'ya oranı ise %26,6'yı buldu (BDDK, 2003).

2.2. TÜRK BANKACILIK SEKTÖRÜNDE FİNANSAL BAŞARISIZLIK ÖNGÖRÜSÜ ÇALIŞMALARI

Türk bankacılık sektöründe yaşanan banka finansal başarısızlıkları yerli ve yabancı çok sayıda araştırmacının ilgisini çekmiştir. Bu konuda yapılan çok fazla sayıda araştırma bulunmakla birlikte bu bölümde en dikkat çekici olanlara kronolojik sırayla değinilecektir.

Canbaş, Çabuk ve Kılıç (2005) Türk Bankacılık Sektörü üzerine yaptıkları çalışmalarında, ANOVA testiyle 49 finansal oran içerisinde başarısız ve başarısız olmayan gruplar arasında ayrıştırıcı özelliğe sahip 12 oranı belirleyerek, bu oranlar içerisinde Temel Bileşen Analizi (PCA) yöntemiyle toplam varyansın %78.83'ünü açıklayan 3 faktör ortaya koymuşlardır. Bu 3 faktör; ayrıştırma analizi, lojit ve probit yöntemleri için girdi olarak kullanılmış ve yöntemlerin finansal başarısızlıktan 1 yıl öncesi için sırasıyla %90, %87.5 ve %87.5 oranında doğru sınıflandırmalarda buldukları görülmüştür. Ayrıca, çalışmada CAMELS kriterlerinin Türk ticari bankaları için bire bir uygun sonuçlar vermediği gerçekleştirilen temel bileşen analizi sonuçlarından biri olarak ifade edilmiştir. Bu sonucun, Türkiye'deki düzenleyici ve denetleyici kurumların farklı bir uygulama içerisinde bulunmalarından kaynaklanmış olabileceği belirtilmiştir.

Benli (2005), Türk bankacılık sektöründe varyans analizi testi uygulayarak 49 finansal oran içerisinde tespit ettiği 12 oranla, lojistik regresyon ve yapay sinir ağı modellerinin başarısızlığı 1 yıl öncesinde, sırasıyla %84,2 ve %87 oranlarında doğru tahmin etme başarısı gösterdiğini ve yapay sinir ağlarının lojistik regresyona göre daha başarılı olduğunu saptamıştır.

Kılıç (2006) çok kriterli karar analizine (ÇKKA) dayanan bir erken uyarı modeli oluşturmuştur. 57 özel sermayeli bankanın dahil edildiği çalışmada (21 finansal başarısız), öncelikle finansal başarısızlığın yaşanmasından bir yıl öncesi için, başarısız olan ve faaliyetini sürdüren bankaları birbirinden ayırt eden 10 finansal oran ANOVA yöntemiyle saptanmış ve standardize edilmiştir. Tespit edilen oranların CAMELS'le birebir örtüşmese de yakın olduğu ifade edilen çalışmada, ÇKKA'ya dayalı bir yaklaşım olan ELECTRE TRI modeli, bankaları %93 oranında doğru sınıflandırmıştır. ELECTRE TRI modeli Canbaş, Çabuk ve Kılıç'ın (2005) uyguladığı ayrıştırma analizi, lojit ve probit modellerinden daha başarılı bulunmuştur.

Karacabey (2007) değişken seçiminde kullanılan faktör analizi ve ayrıştırma analizi gibi süreçlerin başta bilgi kaybı olmak üzere bazı sakıncalarını giderebilmek amacıyla, matematiksel

programlama tabanlı ayırıştırma analizi amacıyla kullanılan minimum sapma modeline yeni kısıtlar eklemek suretiyle, modelin tahminde kullanacağı özellikleri kendisinin seçmesi sağlamıştır. ve yukanda bahsedilen birden fazla aşamalı süreç tek bir model ile ikame edilmiştir. Geliştirilen düzeltilmiş minimum sapma modeliyle, 39 özel sermayeli Türk bankasının 1994-2001, 18'i başarısız toplam 39 banka verileri kullanılarak test edilmiştir. 1, 2 ve 3 yıl öncesinden öngörülerin yapıldığı çalışmada, önerilen model 1 yıl öncesi için %92,3 oranında doğru sınıflandırma başarısı göstermiş ve faktör analizi destekli ayırıştırma analizinden daha başarılı bulunmuştur.

Ravi ve Pramodh (2008) İspanya ve Türkiye bankacılık verilerini kullanarak, *threshold accepting* (TA) yöntemiyle eğitilen temel bileşenli yapay sinir ağı modeli ile finansal başarısızlık tahmini gerçekleştirmişlerdir. İspanya veri seti için 66, Türkiye veri seti için ise 40 bankanın yer aldığı çalışmada, hazırlanan yeni değişken seçimi yöntemiyle İspanya için 6, Türkiye veri seti için 7 finansal oran seçilmiştir. Çalışma sonucunda kurulan modellerden en yüksek başarı oranı İspanya veri seti için %96.6, Türkiye veri seti için ise %100 olarak bulunmuştur. Çalışmanın en önemli sonuçlarından birinin önerilen modelin, genelleştirme açısından geliştirilerek aşırı uyum problemini aşması olduğu ifade edilmiştir.

Çinko ve Avcı (2008) 19'u TMSF'ye devredilen toplam 44 banka için, temsili CAMELS dereceleri ve bileşenlerini ayırma analizi, lojistik regresyon ve yapay sinir ağı modellerinde kullanarak bankaların finansal başarısızlıklarının öngörmeye çalışmış, sonuç olarak ise CAMELS bileşenlerinin ülkemiz bankacılık sistemine tam olarak uymadığı sonucuna ulaşmışlardır. Bu sonuç, Canbaş, Cabuk ve Kılıç'ın (2005) CAMELS bileşenlerinin ülkemize uygun olmadığı yönündeki bulgularını desteklemektedir.

Yıldız ve Akkoç (2009) ise finansal başarısızlığın öngörüsünde sinirsel bulanık ağ yöntemini kullanmışlardır. Modelin karar alma sürecinin yorumlanabilir olduğu çalışmada, 19'u finansal başarısız toplam 40 banka kullanılmıştır. Bağımsız değişken seçimi için yapılan t-testi sonucunda 23 finansal oran gruplar arasında ayırt edici bulunmuş, bu oranlarla ayırıştırma analizi yapılmıştır. Ayırıştırma analizinden elde edilen fonksiyonda yer alan 3 bağımsız değişken sinirsel bulanık ağ yönteminde girdi olarak kullanılmıştır. Sinirsel bulanık ağ modeli (%81,25), ayırıştırma analizine (%75) göre daha başarılı bulunmuş fakat bu fark istatistiksel olarak anlamlı görülmemiştir.

Chauhan, Ravi ve Chandra (2009) Türkiye, İspanya ve ABD bankacılık sektörü üzerinde yaptıkları çalışmada, *Differential evolution trained wavelet neural network* (DEWNN) ve *threshold accepting trained wavelet neural network* (TAWNN) isimlerini verdikleri dalgacık yapay sinir ağlarının öngörme performanslarına bakmışlardır. Türkiye veri setinde 18'i başarısız 40 banka, İspanya veri setinde 37'si başarısız 66 banka ve ABD veri setinde 65'i başarısız 129 banka bulunmaktadır. Kurulan modellerden TAWNN Türkiye için %100 oranında doğru sınıflandırma gerçekleştirirken, İspanya ve ABD veri setlerinde %88,33 ve %90,83 oranlarında kalmıştır. Çalışmada 10 bölmeli çapraz doğrulama kullanılırken, bağımsız değişkenlerin seçimi için Garson tarafından 1991 yılında yapay sinir ağlarında uygulanmış olan bir yöntem tercih edilmiştir.

Çelikyılmaz, Türkşen, Aktaş, Doğanay ve Ceylan (2009) iki sınıflı örüntü tanıma problemlerinin çözümü için geliştirilen IFCF (*improved fuzzy classifier functions*) modelini 4 farklı sınıflandırma probleminin çözümü için kullanmışlardır. Çalışmada ele alınan problemlerden biri de bankaların finansal başarısızlığının öngörülmesi olmuştur. TMSF'ye devredilen 21 bankanın bulunduğu toplam 44 bankadan oluşan veri setiyle, içlerinde adimsal lojistik regresyon'un bulunduğu bir dizi istatistiksel yöntem sonrasında iki grup arasındaki farkları ortaya koyan 11 bağımsız değişken seçilmiştir. IFCF modeli 1, 2 ve 3 yıl öncesi için sırasıyla %98, %94 ve %97 oranlarında doğru sınıflandırma gerçekleştirmiştir. Araştırmacılar modelin her bir küme için otomatik olarak bulanık sınıflandırma fonksiyonlarını üretmesinin ve performansının farklı örneklem setlerinde çok fazla oynaklık göstermemesinin modelin önemli avantajlarından olduğunu belirtmişlerdir.

Ban ve Mazıbaş (2009) ise Çok Katmanlı Algılayıcı (MLP) ve Genelleştirilmiş İleri Sürümlü Ağlarla (GFW) 1995-2000 dönemine ait veriler kullanılarak, 1997 - 2000 arası 4 yıllık bir dönem için veri seti dışı tahminler gerçekleştirmişlerdir. Ağ modellerine ilave olarak, sınıflandırma performansının karşılaştırılabilmesi amacıyla ayrıştırma ve lojistik regresyon analizleri de yapılmış ve ağ modellerinin diğer modellerden daha iyi performans gösterdiği belirlenmiştir.

Boyacıoğlu, Kara ve Baykan (2009) CAMELS kategorilerine uygun şekilde seçtikleri 20 finansal oranı kullanılarak Türkiye'de finansal başarısızlığa uğrayan 21 bankanın dahil olduğu toplam 65 bankalık veri seti üzerinde; 4 farklı yapay sinir ağları, 3 farklı istatistik yöntem ve destek vektör makineleri ile finansal başarısızlık öngörüsünde bulunmuşlardır. Veri setinin eğitim ve test olarak ikiye bölüdüğü çalışmada, rastgele seçilen 7'si finansal başarısız 22 banka

test için kullanılmıştır. 20 finansal oran içerisinde ise grupları ayırt edici özelliklere sahip 9 oran seçilmiş ve hem ham veri seti, hem de seçilen verilerden oluşan set *z-skor* yöntemiyle normalize edilmiştir. Bu şekilde bir açıdan 4 farklı veri seti elde edilmiştir. Aynı zamanda, 20 finansal orana faktör analizi de uygulanarak toplam varyansın %80,3'ünü açıklayan 7 faktör de belirlenmiş ve istatistiksel modellerde bağımsız değişkenler olarak kullanılmıştır. Çalışma sonucunda en başarılı sonucu, yapay sinir ağları verirken (MLP ve LVQ: %95,5, %100), destek vektör makinelerinin (DVM) ve çok değişkenli istatistik yöntemlerinin performanslarının da yeterli olduğu sonucuna varılmıştır.

Ravisankar ve Ravi (2010) daha öncesinde finansal başarısızlık alanında kullanılmamış olan Group Method of Data Handling (GMDH), Counter Propagation Neural Network (CPNN) ve fuzzy Adaptive Resonance Theory Map (fuzzy ARTMAP) teknikleriyle, İspanya, Türkiye, İngiltere ve ABD bankacılık sektöründe yaşanmış finansal başarısızlıkları öngörmeye çalışmışlardır. Bağımsız değişkenlerin seçimi için t-istatistiği, f-istatistiği ve GMDH metodlarının kullanıldığı çalışmada, bütün veri setleri için f-istatistiği ve t-istatistiğinin aynı değişkenleri seçtiği gözlenmiştir. Tahmin için oluşturulan modeller hem tek başlarına (stand alone), hem de değişken seçim metodları tarafından oluşturulan bağımsız değişken setlerinin girdi alındığı farklı hibritler oluşturularak karşılaştırılmıştır. 10-bölmeli çapraz doğrulama uygulanan çalışmada, GMDH hem değişken seçimi uygulandığı hem tek başına olduğu durumda diğer modellere göre başarılı sonuçlar vermiştir. Araştırmacılar Türkiye veri seti için, 7 bağımsız değişken ve GMDH yöntemini kullanarak finansal başarısızlığı %100 oranında doğru öngörmüşlerdir.

Ekinci ve Erdal (2011) 1996–2000 döneminde Türkiye’de faaliyet gösteren özel sermayeli 35 ticari bankayı kapsayan çalışmalarında; DVM, MLP yapay sinir ağı yöntemi ile karşılaştırılmışlardır. Çalışmada DVM’nin MLP yöntemine açık bir üstünlüğü bulunduğu bulgusuna ulaşılmıştır.

3. BÖLÜM

TÜRKİYE’DE YERLEŞİK BANKALAR İÇİN BİR AMPİRİK UYGULAMA

3.1. ÇALIŞMANIN AMACI

Finansal piyasalar aracılığı ile tasarrufların yatırıma dönüştürülmesi ülke ekonomileri için büyük önem taşımaktadır. Ülkelerin ekonomik anlamda kalkınabilmesi için sağlıklı bir şekilde işleyen bankacılık sistemine ihtiyaçları vardır. Bu nedenle düzenleyici otoriteler, finansal piyasaların güven ve istikrarın sağlanabilmesi için bankaların finansal durumlarını sürekli olarak değerlendirmek ve ileriye yönelik gerçekçi öngörülerde bulunmak durumundadırlar. Bankaların olası finansal başarısızlıkları, piyasalardaki güven ve istikrar duygusunu temelden sarsabilecek bir etkiye sahiptir. Dolayısıyla bunların öngörülebilmesi; düzenleyici otoriteler, banka sahipleri, yatırımcılar, kredi verenler ve denetçiler gibi bir çok paydaş için önemli fırsatlar sunabilecektir. Özellikle düzenleyici ve denetleyici otoriteler açısından yapılacak doğru öngörüler ve zamanında alınacak önlemler ile olası bir finansal başarısızlığın önüne geçilmesi veya en azından maliyetlerinin azaltılması sağlanabilecektir.

Bu çalışmanın amacı, karar ağaçları yöntemi kullanılarak 1997-2001 dönemleri içerisinde finansal başarısızlığa uğrayan bankaların incelenmesiyle, bankaların finansal başarısızlıklarını öngören bir erken uyarı sistemi geliştirebilmektir. Geliştirilecek modelle, bankaların başarısızlığa uğrama nedenleri analiz edilmeye çalışılacaktır. Çalışma sonucunda oluşturulacak model, daha önce bu alanda yapılmış çalışmalarla kıyaslanarak, söz konusu modellerin performansları arasındaki bir farklılık olup olmadığı incelenecektir.

Çalışmada 1997-2001 yılları arasında TMSF’ye devredilen bankalar finansal başarısızlığa uğramış bankalar olarak kabul edilmiş ve 19’u başarısız toplam 40 bankaya ait finansal oranlar kullanılarak kurulan modelle başarısızlığa uğrayan bankaların 1 yıl öncesinden öngörülmesi hedeflenmiştir.

3.2. ÇALIŞMADA KULLANILAN VERİ SETİ

Çalışmada kullanılan veri seti Türkiye Bankalar Birliği'nin resmi internet sitesinden elde edilmiştir. Veri seti içerisinde 1988-2000 yılları arası için yıllık bazda seçilmiş finansal oranlara yer verilmiştir.

Finansal başarısızlık çalışmalarının önemli bir kısmında olduğu gibi bu çalışmada da küçük bir örneklem setiyle çalışılmak zorunda kalınmıştır (Li ve Sun, 2008). Toplamda 76 bankanın bulunduğu veri setinde:

- mevduat toplama izni bulunmayan, kredi kullanılmak üzere belirli özel görevleri yerine getirmeye çalışan Kalkınma Yatırım bankaları(15) ile
- sermaye yapıları itibarıyla ayrışan ve finansal başarısızlığa uğrama açısından özel ticari bankalarla kıyas edilmeleri çok doğru sonuçlar vermeyecek olan Kamu bankaları(4) ve Yabancı bankalar(17)

çalışma kapsamı dışında tutulmuştur. Çalışmada belirlenen bu kapsam diğer bir çok finansal başarısızlık çalışmalarında izlenen yöntemlerle de uygunluk göstermektedir (Ravi ve Pramodh, 2008; Yıldız ve Akkoç, 2009; Canbas, Cabuk ve Kilic, 2005).

Sonuçta elde edilen 40 bankaya ait veri seti içerisinde yer alan 19 banka mali yapılarının bozulmuş olması nedeniyle 1997-2001 yılları arasında TMSF'ye devredilmiştir. Finansal başarısızlığa uğrayan bankalar ve TMSF'ye devredilme tarihlerine Tablo 2'de yer verilmiştir.

Banka Adı	TMSF'ye Devredilme Tarihi
Türk Ticaret Bankası	06.11.1997
Bank Ekspres	12.12.1998
İnterbank	07.01.1999
Esbank	21.12.1999
Egebank	21.12.1999
Yurtbank	21.12.1999
Yaşarbank	21.12.1999
Sümerbank	21.12.1999
Etibank	27.10.2000
Bank Kapital	27.10.2000
Demirbank	06.12.2000
Ulusalbank	28.02.2001

İktisat Bankası	15.03.2001
Sitebank	09.07.2001
Tariřbank	09.07.2001
Birleřik Fon Bankası (Bayındırbank)	09.07.2001
Kentbank	09.07.2001
EGS Bank	09.07.2001
Toprakbank	30.11.2001

Tablo 2 TMSF'ye devredilen bankalar ve devredilme tarihleri (TMSF, 2011)

Veri seti içerisinde her bir bankaya ait sermaye, aktif kalitesi ve likidite gibi toplam 9 başlık altında 49 farklı finansal orana yer verilmiştir. Söz konusu oranlardan sermaye standart rasyosu haricindekiler bankaların ilgili yıl bilançoları kullanılarak TBB tarafından Ek-1'de verilen formüllerle hesaplanmıştır. Tablo 3 finansal oranlara ilişkin tanımlayıcı istatistikleri sunmaktadır.

Kod	Finansal Oran	Gözlem	Ort.	Std.Sap.	Min	Max	25th	Median	75th
S1	Sermaye Standart Rasyosu	35	16,61	20,24	-36,10	96,00	9,10	12,10	22,40
S2	(Özkaynak+Kar)/Toplam Aktif	40	8,15	24,24	-120,40	46,70	6,60	9,71	14,10
S3	(Özkaynak+Top. Kar)/(Mev.+Mev.Dışı Kay.)	40	14,49	22,75	-60,08	94,70	7,70	11,56	18,10
S4	Net Çalışma Sermayesi/Toplam Aktif	40	-0,88	27,99	-133,63	34,36	0,88	4,66	7,31
S5	(Özkaynak+Top.Kar)/(Top.Aktif+Gayri Nakdi Krediler)	40	4,20	9,32	-32,71	26,01	2,55	4,29	5,65
S6	Döviz Pozisyonu/Özkaynak	40	196,64	240,02	-493,67	804,12	47,00	153,00	305,40
A1	Top. Kredi/Top. Aktif	40	32,60	13,12	0,64	60,67	24,74	34,86	41,41
A2	Takipteki krediler/Top. Krediler	40	22,08	72,68	0,00	397,54	1,19	2,64	6,62
A3	Duran Aktifler/Top. Aktifler	40	16,40	14,12	1,27	63,72	5,12	12,82	23,27
A4	YP Aktifler/YP Pasifler	40	66,48	23,19	15,98	109,45	46,59	69,60	82,72
L1	Likit Aktifler/T.Aktifler	40	38,76	19,54	4,07	92,69	28,42	32,67	50,18
L2	Likit Aktifler/(Mevduat + Mev.Dışı Kay.)	40	48,04	26,95	3,39	152,49	34,54	42,80	60,87
L3	YP Likit Aktifler/YP Pasifler	40	36,58	20,52	7,07	109,27	23,60	34,41	42,76
K1	Net Dönem Karı/Ortalama T.Aktifler	40	-3,60	18,82	-106,87	7,01	0,13	0,86	3,57
K2	Net Dönem Karı/Ortalama Özkaynaklar	40	-27,37	269,03	-1492,52	273,30	2,61	11,08	40,27
K3	Net Dönem Karı/Ortalama Ödenmiş Sermaye	40	-68,52	438,48	-2597,04	156,33	2,31	12,75	56,48
K4	Vergi Öncesi Kar/Ortalama T.Aktifler	40	-2,95	19,11	-106,87	11,20	0,27	1,24	4,04
K5	Takipteki Alacak Provizyonu/T.Krediler	40	10,94	40,94	0,00	226,08	0,27	0,95	2,07
K6	Takipteki Alacak Provizyonu/T.Aktifler	40	2,79	10,69	0,00	62,88	0,14	0,29	0,68
G1	Takip.Alac.Son.Net Faiz Gel./Ort.T.Aktif.	40	7,42	13,60	-61,70	20,74	5,61	8,40	15,14
G2	Faiz Gelirleri/Faiz Giderleri	40	177,70	65,29	66,68	329,23	129,51	171,24	213,49
G3	Faiz Dışı Gelirler/Faiz Dışı Giderler	40	-13,29	82,01	-290,23	121,98	-61,35	-6,10	54,95
G4	Toplam Gelirler/Toplam Giderler	40	106,89	28,69	-2,51	170,41	101,58	106,62	123,05
G5	Faiz Gelirleri/Ort. Getirili Aktifler	40	41,41	21,71	22,71	130,33	27,86	34,91	49,63
G6	Faiz Giderleri/Ort.Götürülü Aktifler	40	20,40	10,50	9,37	65,65	13,28	17,94	25,37
G7	Faiz Giderleri/Ort.Getirili Aktifler	40	26,93	19,67	9,35	103,14	15,77	20,82	33,00
G8	Faiz Gelirleri/T.Gelirler	40	67,07	232,60	-1360,39	168,74	85,76	99,22	119,48
G9	Faiz Dışı Gelirler/T.Gelirler	40	32,93	232,60	-68,74	1460,39	-19,48	0,78	14,24

G10	Faiz Giderleri/T.Giderler	40	64,74	12,88	28,96	91,47	55,83	62,42	77,32
G11	Faiz Dışı Giderler/T.Giderler	40	35,26	12,88	8,53	71,04	22,68	37,58	44,17
SB1	Şube Başına Toplam Aktif	40	14497,97	18478,90	758,29	114783,60	5363,09	10140,37	18219,87
SB2	Şube Başına Toplam Mevduat	40	8799,05	10140,24	460,91	61685,10	3888,49	5988,31	10062,01
SB3	Şube Başına TL Mevduat	40	2880,38	3406,37	134,82	18188,86	1013,17	1786,66	3129,88
SB4	Şube Başına YP Mevduat	40	5918,67	8503,40	321,36	55183,90	2270,47	4323,60	6771,41
SB5	Şube Başına Personel	40	22,22	8,75	6,55	44,50	16,26	20,22	26,79
SB6	Şube Başına Kredi	40	4174,85	4333,17	4,89	23329,90	1726,63	2867,54	4699,48
SB7	Şube Başına Net Kar	40	-614,81	3257,98	-14098,08	2735,00	2,90	63,10	486,03
F1	(Personel Gideri+Kıdem Tazminatı)/T.Aktif	40	2,87	1,57	0,91	8,82	1,82	2,52	3,28
F2	(Personel Gideri+Kıdem Tazm.)/Personel Sayısı (Milyar TL)	40	13,77	7,69	1,27	42,00	6,99	13,35	17,94
F3	Kıdem Tazminatı/Personel Sayısı (Milyar TL)	40	0,29	0,30	0,00	0,96	0,03	0,16	0,51
F4	Faaliyet Gideri/T.Aktif	40	3,86	2,24	1,34	13,18	2,43	3,29	4,52
F5	Vergi Hariç Ayrılan Provizyonlar/T.Gelirler	40	15,74	48,33	0,00	293,02	0,81	2,68	6,83
F6	Vergi Dahil Ayrılan Provizyonlar/T.Gelirler	40	16,52	48,12	0,42	293,02	1,09	4,25	7,51
SC1	Toplam Aktifler (Sektör)	40	1,51	2,04	0,05	7,47	0,37	0,83	1,44
SC2	Toplam Krediler (Sektör)	40	1,67	2,53	0,00	8,61	0,33	0,76	1,55
SC3	Toplam Mevduat (Sektör)	40	1,49	1,85	0,02	6,80	0,40	0,91	1,68
GR1	Toplam Aktifler (Grup)	38	9,45	15,57	0,10	54,70	0,92	1,99	13,75
GR2	Toplam Krediler (Grup)	38	13,44	27,54	0,00	129,56	0,62	1,50	14,28
GR3	Toplam Mevduat (Grup)	38	8,30	12,93	0,05	56,96	0,90	2,18	12,32

Tablo 3 Finansal oranlara ilişkin tanımlayıcı istatistikler

3.3. METODOLOJİ

3.3.1. Sınıflandırma ve regresyon ağaçları (CART)

Sınıflandırma ve regresyon ağacı (CART), ilk olarak 1984 yılında istatistikçiler L.Breiman, J.H. Friedman, R.A. Olshen ve C.J. Stone tarafından ortaya çıkarılan, sınıflandırma ve regresyon amacıyla yaygın olarak kullanılan bir karar ağacı modelidir. CART, ikili bir ağaç yapısı içerisinde, kullanılan verileri alt kümelere ayırmakta ve böylece her bir alt küme içindeki durumlar, bir önceki alt kümeden daha homojen olmasını sağlamaktadır. Bu yinelemeli süreç, homojenlik kriterine ulaşıncaya veya diğer bazı durma kriterleri sağlanıncaya kadar etmektedir. Bu yöntemde, ağacın farklı düzeylerinde aynı değişken birden fazla kullanılabilir. Ağacın yapısı önceden belirlenmemekte, verilerin işlenmesiyle türetilmektedir (Oğuzlar, 2004).

CART, kök düğümünde, verilerin iki gruba bölünmesi için en iyi değişkenin seçilmesini sağlar ve farklı bölümlendirme (splitting) kriterleri kullanır. Bölümlendirme kriterlerinin tamamı, her bir alt kümedeki sınıf etiketlerini mümkün olduğunca homojen olacak biçimde bölümlendirmeyi amaçlamaktadır. Bölümlendirme prosedürü kök düğümden sonra bütün alt düğümlerin de her birinde ardışık olarak uygulanır. Bu şekilde, kesin bir katışıklık (*impurity*) ölçüsüne bağlı olarak, bölümlendirmeler yoluyla sınıflar belirlenmeye çalışılmaktadır.

CART yönteminde kullanılan dört farklı homojenlik ölçüsü mevcuttur. Kategorik hedef değişkenler için Gini, Twoing kullanılırken sıralayıcı hedef değişkenleri için ‘Sıralı Twoing’ ve sürekli hedef değişkenler için ise en küçük kareli sapma (LSD) kullanılmaktadır (Oğuzlar, 2004). Bankaların finansal başarısızlığının öngörülmesi probleminde bağımlı bir değişkenimiz olduğu için bu problemde Gini ve Twoing ölçütleri kullanılabilir.

3.3.1.1. Katışıklık (*Impurity*) Ölçütü

CART yönteminde sınıflandırma problemleri içerisinde en fazla kullanılan katışıklık ölçütü olan Gini indeksi bir t düğümü için aşağıdaki şekilde yazılabilir:

$$g(t) = 1 - \sum_j [p(j/t)]^2$$

Burada $p(j/t)$ t düğümündeki j sınıfına ait bağıl olasılıktır (Ioannidis ve diğerleri, 2010). Her hangi bir düğümde durumlar kategoriler arasında eşit biçimde dağıldığında Gini indeksi maksimum değerini alır. Bir düğümdeki durumlar aynı kategoriye ait olduğunda ise Gini indeksi 0'a eşit olacaktır.

Bir p düğümü k parçaya bölüneceği zaman bölünme kalitesi şöyle hesaplanır:

$$g_{split} = \sum_{i=1}^k \frac{n_i}{n} g_i$$

$n_i = i$ düğümü üzerindeki kayıt adedi

$n = p$ düğümü üzerindeki kayıt adedi

CART karar ağaçlarında kategorik hedef değişkenleri için kullanılabilir bir diğer alternatif bölünme kriteri ise Twoing indeksidir. Twoing indeksi, hedef değişken kategorilerinin iki süper sınıfa bölümlendirilmesine ve ardından bu iki süper sınıfa dayalı olarak kestirim değişkenindeki en iyi bölünmenin bulunmasına dayalıdır. t düğümünde s bölünmesi için Twoing kriter fonksiyonu şu şekilde tanımlanabilir (Soman ve diğerleri, 2006):

$$GINI_{twoing}(s, t) = \frac{p_L \cdot p_R}{4} \left[\sum_j \left| p\left(\frac{j}{t_L}\right) - p\left(\frac{j}{t_R}\right) \right| \right]^2$$

fonksiyonda yer alan t_L ve t_R , s bölünmesi tarafından yaratılan düğümleri, p_L ve p_R ise t düğümünde sol ve sağ alt düğümlere giden örneklem oranlarını göstermektedir. s bölünmesi, bu kriteri maksimize eden bölünme olarak belirlenir. j ise bölümlendirilecek olan kategorileri ifade etmektedir.

3.3.1.2. Budama (*Pruning*)

CART algoritmasında, yukarıda açıklanan bölümlendirme kriterleri kullanılarak, verilen eğitim veri seti üzerinden yinelemeli olarak bir CART ağacı oluşturulur. Yalnız bu ağacın alt dallarına ulaşıldığında, hata oranı gittikçe düşmeye devam etse de genel olarak istatistiksel açıdan anlamsız bölümlendirmelere gidilmeye başlanır. Bu durum, eğitim veri setinin ağaç modeli tarafından ezberlenmeye başladığını ve ağacın veri setine aşırı uyum gösterdiğini ifade eder. Aşırı uyum durumu, karar ağaçlarında budamaya gidilmesine yönelik motivasyonu tetikleyen temel

unsurdur. Karar ağaçlarında budama yapılmasının mutlak bir şekilde istatistiksel olarak modelin sınıflandırma başarısını arttıracacağı düşünülmemelidir. Büyük ölçekteki veri setleri kullanılarak gerçekleştirilen çalışmalarda dahi budamanın, karar ağaçlarında sınıflandırma başarısının azalmasına neden olabildiği görülmüştür (Soman ve diğerleri, 2006).

Karar ağaçlarında budamanın nasıl yapılacağına ilişkin iki temel yaklaşım bulunmaktadır. Bunlardan ilki, eğitim seti kullanılarak ağaç tümüyle oluşturulduktan sonra üzerinden geçilerek gereksiz bölünmelerin budanması olarak kabul edilen “*post-pruning*” yaklaşımıdır. Diğeri ise ağacın belli bir seviyeye ulaşmasından sonraki bölünmelerinin güvenilebilir olmadığı gerekçesi ile ağacın büyümesini durdurulması şeklinde ifade edilebilecek “*pre-pruning*” yaklaşımıdır. “*pre-pruning*” yaklaşımı, “*post-pruning*”e göre işlem yükünün azaltılabilmesi anlamında ciddi bir avantaja sahip olmakla birlikte, ağacın büyümesinin erken durdurulması gibi bir riski de içermektedir (Soman ve diğerleri, 2006).

3.3.1.3. Maliyet-Karmaşık Budama Yöntemi

CART yönteminde ağacın budanması için maliyet-karmaşık budama (*cost-complexity pruning*) metodu kullanılmaktadır. Bu metod iki basit aşamadan oluşmaktadır (Soman ve diğerleri, 2006):

1. Sezgisel yöntemler aracılığıyla bazı alt ağaç serilerinin belirlenmesi,
2. Bu ağaçların gerçek hata oranları tahmininin kullanılarak, budanması planlanan en iyi alt ağacın(T_i) seçimi.

Birinci adımın temel mantığı, T_i ağacından her bir budanan yaprak için hata oranını en az artıracak şekilde elde edilecek T_{i+1} ağacının seçilmesidir.

$|N_{T_t}|$: T_t alt ağacındaki yaprak sayısını,

$R(t)$: bir alt ağaç budanarak tek bir yaprağa dönüştürüldüğünde bu düğümdeki hata maliyetini,

$R(T_t)$: alt ağaç budanmadığı durumda alt ağaçtaki hata maliyetini

ifade ettiği, t düğümünde T alt ağacı budanacağı zaman, eğitim seti üzerindeki hata oranı :

$$R(t) - R(T_t)$$

kadar artarken, yaprak sayısı $|N_{T_t}| - 1$ kadar azalır. Bu durumda;

$$\alpha = \frac{R(t) - R(T_t)}{|N_{T_t}| - 1}$$

oranı bize her bir budanan yaprak başına hata oranında ne kadarlık bir artış olduğunu verecektir. Maliyet-karmaşık (*Cost-complexity*) algoritmasında kök düğüm hariç bütün düğümler için bu oran hesaplanarak, en küçük α değerine sahip alt ağaç budanmak için seçilir (Soman ve diğerleri, 2006).

Sonuçta elde edilen ağacın büyüklüğü, budama (*pruning*) sürecinin bir sonucu olacaktır. Çok büyük bir ağaçlar, aşırı uyuma (*overfitting*) ve çok küçük ağaçlar ise yetersiz tahmin gücüne neden olabilmektedir (Oğuzlar, 2004).

3.3.1.4. CART'nin Avantaj ve Dezavantajları

CART analizinin finansal başarısızlığın öngörülmesi anlamında en değerli özelliğinin analiz sonuçlarının “eğer-ise” şeklinde kurallar halinde ifade edilerek yorumlanabilir olması olduğu söylenebilir (Li ve diğerleri, 2010). CART ikili bir ağaç yapısına sahip olduğu için, kuralları uzman olmayan kişiler tarafından dahi kolayca yorumlanabilmektedir.

CART karar ağaçlarının veri seti içerisinde yer alan bütün özellikleri değerlendirebilmesi ve problemin çözümü için önemli görülen özellikleri kendi iç süreçleri içerisinde belirleyebilmesi de yöntemin üstün taraflarından birini teşkil etmektedir (Li ve diğerleri, 2010).

CART, içerisinde eksik değerler bulunan değişkenleri (özellik) de vekillik (*surrogate*) yöntemini kullanarak modelin içerisine dahil edebilmektedir. Bu yöntemde ağaç yapısı oluşturulurken ağaçta yer alacak her bir özellik için vekil özellikler saptanmaktadır. Herhangi bir gözleme ait işlem yapılırken eksik değerlerle karşılaşılması durumunda, eksik değer bulunduğü özelliğün vekiline bakılır ve bu şekilde işlem aksatılmadan devam ettirilmeye çalışılır. Eğer birinci vekile ilişkin gözlem değeri de eksikse sırasıyla diğer özellik değerleri kullanılır. Bu özelliğüyle CART, veri seti içerisinde eksik değerler bulunduğunda avantajlı bir yöntem olarak öne çıkmaktadır (Pham, 2006).

CART analizinin bir başka avantajı da diğer modellere nazaran göreceli olarak az miktarda girdi ile çalışabilmesidir. Diğer modelleme yöntemleri araştırmacılara çok fazla girdi gereksinimi yüklemekte, geçici sonuçların analizinin yapılması ve ilgili yöntemin modifikasyonu gerekebilmektedir (Oğuzlar, 2004).

CART yönteminin özellikle istatistiksel yöntemlere nazaran avantajlı yönlerinden birisi de değişkenler üzerinde herhangi bir dağılımsal varsayımda bulunmamasıdır. Bu yönüyle istatistiksel tekniklerin kullanımının mümkün olmadığı durumlarda kolaylıkla uygulanabilmektedir. CART analizinde kullanılacak değişkenler sürekli değişkenler olabileceği gibi, sınıflayıcı veya sıralayıcı yapıya sahip kategorik değişkenler de olabilmektedir. Bu da modelin esnekliğini ciddi şekilde arttırmaktadır (Pham, 2006).

CART analizinin, finansal başarısızlık alanındaki önemli artılarında biri de sınıflandırma hatalarına ilişkin asimetrik maliyetleri dikkate alabilmesidir. Bu şekilde, Tip-I ve Tip-II hata maliyetlerinin farklılığını göz önünde bulundurarak daha az hata maliyetli sınıflandırmalar yapabilmektedir.

CART analizinin avantajlarının yanında bazı dezavantajları da bulunmaktadır. Bunlardan biri CART'nin ikili ağaç yapısından kaynaklanan kararsızlık (*instability*) durumudur. Eğitim setinde meydana gelecek küçük değişimler çıktı ağaç yapısında dramatik değişimlerin olmasına neden olmaktadır. Hiyerarşik yapısından dolayı, eğitim setindeki oynamaların üst düğümlerden birinde meydana getirebileceği bir değişim, ağacın yapısı bütünüyle değiştirebilmektedir. Bu sorunu çözmek üzere her ne kadar “*bagging*” ve “*boosting*” gibi yöntemler geliştirilmiş olsa da bu yöntemlerin kullanımı karar ağaçlarının üstün özelliklerinden biri olan kolay işletilebilirliğinden taviz verilmesine neden olmaktadır (Pham, 2006).

Diğer bir dezavantaj ise, CART yönteminin göreceli olarak yeni bir analiz olması ve geleneksel istatistikçiler tarafından kabulünde sorunlar gözlenmesi olarak gösterilebilir. Gelişen teknoloji dünyasında artık sorun olmaktan çıkmaya başlasa da işlem zamanlarının, diğer ağaç yapısına dayalı modeller ile kıyaslandığında daha uzun olması yöntemin sorunlu yönlerinden biridir (Oğuzlar, 2004).

3.3.1.5. Yapılan Çalışmalar

CART analizi ile finansal başarısızlık alanında yapılan en dikkat çekici çalışma Li ve diğerlerinin (2010) 2000-2005 yılları arasında Shanghai ve Shenzhen borsalarına kote 153'ü finansal başarısızlığa uğramış toplam 306 işletme verisi kullanılarak gerçekleştirdikleri çalışmadır. Yazarlar, bu alanda yeterince uygulamasının bulunmadığını ifade ettikleri CART yöntemini ve en çok kullanılan 10 veri madenciliği yöntemi içerisinde DVM, "k-en yakın komşu" algoritmaları ile en sık kullanılan istatistiksel yöntemlerden olan ayrıştırma analizi ve lojistik regresyonu karşılaştırmışlardır. CART haricindeki diğer yöntemler için, adımsal ayrıştırma analizi özellik seçimi metodu olarak benimsenmiştir. Yöntem olarak, Li ve Sun (2008)'deki yöntemin benimsendiği çalışmada, CART'nin diğer yöntemlere nazaran daha başarılı sonuçlar verdiği istatistiksel olarak gösterilmiştir. Li vd. adımsal ayrıştırma analizinin CART'nin öngörü performansını arttırmadığı, CART'nin tüm değişken setini girdi olarak almasının daha iyi sonuçlar verdiğini gözlemlemişlerdir.

Ioannidis, Pasiouras ve Zopounidis (2010) 78 farklı ülkeden 944 bankanın 2007-2008 dönemlerine ilişkin veriler üzerinde yaptıkları çalışmalarında, bankaları finansal sağlamlıklarına göre güçlü, yeterli ve zayıf bankalar olmak üzere 3 ayrı kategori içerisinde sınıflandırmaya çalışmışlardır. Bağımlı değişken olarak Fitch derecelendirme kuruluşunun dereceleri benimsenen çalışmada, sadece finansal oranlar kullanılarak gerçekleştirilen modellerin yanı sıra bu oranlarla birlikte Dünya Bankası raporlarında yer alan düzenleyici ve denetleyici otoritelere ilişkin göstergeler ve ülkelerin makroekonomik şartlarını içeren değişkenler kullanılarak ayrı ayrı modeller oluşturulmuştur. Çalışmada sadece finansal oranlar içeren modellerin başarı düzeylerinin düşük olduğu, yapay sinir ağları ve çok kriterli karar alma tekniği (UTADIS) modellerinin CART, k-NN, lojistik regresyon ve ayrıştırma analizi gibi modellerden daha başarılı şekilde sınıflandırmada bulunduğu gözlemlemişlerdir.

Chen (2011) ise Tayvan'da borsaya kote işletmelerin finansal başarısızlığının öngörülmesi üzerine yaptığı çalışmada, karar ağaçları (C5.0, CART ve CHAID) ile lojistik regresyon analizini karşılaştırmıştır. Çalışma sonucunda, temel bileşen analizinin (PCA) kullanımını arttırdıkça karar ağaçlarının sınıflandırma oranları düşerken, lojistik regresyonun bu durumdan etkilenmediğini ve karar ağaçlarının lojistik regresyona nazaran yakın dönemler için çok daha iyi sonuçlar verdiğini ifade etmiştir. Karar ağacı modellerinin içerisinde ise C5.0 algoritmasının az da olsa CART ve CHAID modellerine göre daha iyi sonuçlar verdiğini belirtmiştir.

CART analizi, sahip olduđu özellikleri itibariyle uygulanabilir olmasına rağmen Türk bankacılık sektöründe finansal başarısızlığın öngörülmesi amacıyla şimdiye kadar kullanılmamıştır. Bununla birlikte; bankalarda etkinliğin öngörülmesi, yerli ve yabancı bankaların sınıflandırılması ve kredi skorlama gibi farklı alanlarda CART'nin ve diğerkarar ağaçlarının denendiğı çalışmalar yapılmıştır.

Bu çalışmalardan birinde Seyrek ve Ata (2010) Türk bankacılık sektöründe yer alan 20 mevduat bankasına ait 2003-2008 dönemi verileri üzerinde veri zarflama analizi yöntemi ile bankaların verimlilik ölçümünü gerçekleştirmişler ve sonrasında bankaların verimlilik skorları kullanılarak banka verimliliğinin tahmininde önemli olan finansal performans göstergelerinin neler olduğunu karar ağacı kullanarak tespit etmişlerdir. Çalışma sonucunda, “Toplam Krediler/Toplam Mevduat” oranı ile “Diğerk Faaliyet Giderleri/Toplam Faaliyet Gelirleri” oranının banka verimliliği açısından önemli finansal oranlar olduğu tespit edilmiştir.

Bir diğerk çalışmada ise Albayrak (2009) yerli ve yabancı olarak grup üyeliği belirlenmiş bankaların sınıflandırmasında ayrıştırma analizi, lojistik regresyon ve CART modeli ile oluşturulmuş karar ağacı modellerini karşılaştırmış ve sonucunda karar ağacı modelinin diğerk modellere üstünlük sağladığını göstermiştir.

Model kurmada kullanılan genel metodoloji kısmında da ifade edildiği gibi, ampirik uygulamada verinin toplanması aşamasından sonra verinin ön işleme tabi tutulması ve sonrasında model içerisinde kullanılacak özelliklerin seçilmesidir. TBB'den elde edilen veri seti içerisinde kayda değerk bir eksik veri bulunmamaktadır. Ayrıca veri seti bağımsız denetim raporlarında yer alan finansal tablolardan oluşturulduğu için ayrıca bir ön işleme gerek duyulmamıştır.

3.3.2. Kolmogorov-Smirnov (KS) Testi

Kolmogorov-Smirnov (KS) testi, iki olasılıksal dağılımın aynı dağılımdan gelip gelmediğini test eden parametrik olmayan bir istatistiksel testtir. Parametrik olmayan testlerin en büyük avantajı, anakütle hakkında hiçbir şey bilinmediği zaman güvenle kullanılabilir olmalarıdır. Özellikle örneklem hacminin küçük olduğu durumlarda, istatistiklerin örneklem dağılımı normal dağılıma yaklaşmaz. Bu durumda örneklemin normal dağıldığı varsayımını yapan parametrik testler yerine, Parametrik olmayan bir testin tercih edilmesi daha uygundur. Parametrik olmayan testlerin diğerk önemli bir avantajı da, nominal ve ordinal verilerle yapılabilir olmasıdır.

Parametrik olmayan testlerin gerçekleştirilmesi de, parametrik testlere nisbeten daha kolay ve pratiktir. Parametrik olmayan testlerin dezavantajları, aynı şartlar altındaki parametrik testlerden daha güçsüz olmalarıdır. Özellikle, II. Tip hata ihtimali Parametrik olmayan testlerde daha fazla olmaktadır. Parametrik olmayan testler genellikle, gözlenen değerler arasındaki farkın büyüklüğünden ziyade sadece yönü ile yani, gözlenen değerlerin belli bir değerden büyük veya küçük olup olmadığıyla ilgilendir. Bu sebeple Parametrik olmayan testlerin etkinliği parametrik testlere göre daha zayıftır (Bircan ve diğerleri, 2003).

Yalnız gerçekleştirilen çalışmalarda finansal oranların normal dağılıma uymadıklarının görülmüş olması, bu aşamada Parametrik olmayan testlerin kullanılmasının daha uygun olacağını göstermektedir (Deakin, 1976; So, 1987).

KS testinde H_0 hipotezi, iki örneklemin aynı dağılımdan geldiğini ifade etmektedir.

$$H_0: F_i = F_j$$

Buradaki F_i ve F_j örneklem kümülatif dağılım fonksiyonları:

$$F(x) = \frac{1}{N} \sum_{i=1}^N I_{X_i < x}$$

$$I_{X_i < x} = \begin{cases} 1 & \text{eğer } X_i \leq x \\ 0 & \text{eğer } X_i > x \end{cases} \text{ ve } N = \text{örneklem boyutu}$$

şeklinde ifade edilmektedir. KS testi;

$$D = \sup_x |F_i - F_j|$$

olarak tanımlanan D-istatistiği baz alınarak gerçekleştirilir. D-istatistiği, iki örneklemin kümülatif fonksiyonları arasındaki maksimum farkın mutlak değerini vermektedir. N_1 ve N_2 'nin i ve j örneklemlerinin boyutu ve cv_α 'da KS testi için kritik değeri ifade ettiği durumda;

$$\sqrt{\frac{N_1 N_2}{N_1 + N_2}} D > cv_\alpha$$

olması halinde H_0 hipotezi α seviyesinde reddedilir (Erden ve diğerleri, 2009).

3.4. SINIFLANDIRMA VE REGRESYON AĞACININ KURULMASI

3.4.1. KS Testi İle Özellik Seçimi

Finansal başarısızlığa ilişkin modelin kurulmasına geçmeden önce modelin başarısını artırmak ve daha sağlıklı sonuçlar elde edilebilmesini sağlamak üzere veri seti içerisinde yer alan finansal oranlardan hangilerinin başarısızlığa uğrayan ve uğramayan gruplar arasında ayırt edici niteliklere sahip olduklarının tespit edilmesi gerekmektedir. Bu çalışmada, veri setinin nispeten küçük olması ve veriler üzerinde herhangi bir varsayıma gidilememesi nedeniyle parametrik olmayan bir test olan iki örneklemlili Kolmogorov-Smirnov testi tercih edilmiştir.

Test edilen hipotez:

H_0 : Finansal başarısız olan / başarısız olmayan gruba ait X değişkeni aynı dağılımdan gelmektedir.

H_1 : X değişkeni farklı dağılımlardan gelmektedir.

Test sonucunda, %95 güven aralığında 30 değişken için H_0 hipotezi reddedilemezken, 19 değişken için reddedilmiştir. Bu sonuç bize finansal başarısızlığın 1 yıl öncesinden tespit edilebilmesi için 19 tane ayırt edici nitelikte finansal oranın var olduğunu göstermektedir. Bu oranlar ve test sonucu elde edilen D-istatistiği ile p-değerlerine Tablo 4'te yer verilmiştir.

Değişken	D-İst.	p-değeri	H_0	Değişken	D-İst.	p-değeri	H_0
G7	0,699	0	Red	GR1	0,353	0,192	Kabul
K1	0,652	0	Red	GR2	0,353	0,192	Kabul
S2	0,647	0	Red	SB2	0,336	0,211	Kabul
G6	0,647	0	Red	G3	0,321	0,256	Kabul
S1	0,643	0,002	Red	GR3	0,314	0,313	Kabul
S3	0,637	0,001	Red	F3	0,286	0,389	Kabul
SB6	0,619	0,001	Red	SC2	0,286	0,389	Kabul
K4	0,599	0,002	Red	A2	0,283	0,4	Kabul
S4	0,594	0,002	Red	SB5	0,271	0,458	Kabul
G4	0,594	0,002	Red	A4	0,266	0,482	Kabul
F5	0,594	0,002	Red	G8	0,266	0,482	Kabul
SB7	0,561	0,004	Red	G9	0,266	0,482	Kabul

K3	0,514	0,01	Red	F1	0,256	0,532	Kabul
SB1	0,509	0,011	Red	F4	0,251	0,558	Kabul
G5	0,494	0,015	Red	S6	0,241	0,611	Kabul
F6	0,484	0,019	Red	SC1	0,238	0,624	Kabul
S5	0,471	0,024	Red	SC3	0,238	0,624	Kabul
G2	0,471	0,024	Red	L3	0,233	0,651	Kabul
L2	0,451	0,034	Red	K5	0,221	0,717	Kabul
SB4	0,414	0,066	Kabul	G1	0,221	0,717	Kabul
K2	0,404	0,078	Kabul	A3	0,213	0,756	Kabul
L1	0,398	0,084	Kabul	A1	0,178	0,91	Kabul
G10	0,393	0,091	Kabul	SB3	0,178	0,91	Kabul
G11	0,393	0,091	Kabul	K6	0,168	0,941	Kabul
F2	0,378	0,115	Kabul				

Tablo 4 KS Testi Sonuçları (D-istatistiğine göre sıralı)

KS testi sonucunda ayırt edici özellikte olduğu için seçilen finansal oranlar, Türkiye'ye ilişkin yapılan çalışmalarda seçilen oranlarla karşılaştırılmış ve büyük oranda uyumluluk gösterdiği görülmüştür (Canbas ve diğerleri, 2005; Benli, 2005; Kılıç, 2006; Karacabey, 2007; Ravi ve Pramodh, 2008; Yıldız ve Akkoç, 2009; Chauhan ve diğerleri, 2009; Celikyılmaz ve diğerleri, 2009; Ravisankar ve Ravi, 2010). Bu karşılaştırmaya ilişkin ayrıntılı sonuçlara Ek-3'te yer verilmiştir. Söz konusu çalışmalarda seçilen;

- Faiz Giderleri/T.Giderler (G10),
- (Personel Gideri+Kıdem Tazm.)/Personel Sayısı (F2) ve
- Likit Aktifler/T.Aktifler (L1)

oranları KS Testi sonucunda seçilmeyen; diğer çalışmalarda seçilmemiş olan Vergi Hariç Ayrılan Provizyonlar/T.Gelirler (F5) ve Net Dönem Karı/Ortalama Ödenmiş Sermaye (K3) oranları test sonucunda seçilmiştir.

3.4.2. CART Modelinin Test Edilmesi

TBB'den elde edilen veri seti içerisinde yer alan 49 finansal orandan iki örneklemlili KS testi sonucunda finansal başarısızlığa uğrayan ve uğramayan bankalar arasında ayırt edici nitelikte olduğu görülen 19 finansal oran CART analizine girdi olarak alınmıştır. Bu şekilde uygulanan filtreleyici özellik seçimi yaklaşımı; analizin ilgisiz ve gereğinden fazla özelliklerden arınmasına, işlem zamanlarının düşmesine ve daha anlamlı sonuçlar üretmesine olanak vermektedir. Modelde bağımlı değişken olarak bankaların finansal başarısızlığa uğrama durumu (0/1), bağımsız değişken olarak ise seçilen 19 finansal oran kullanılmıştır.

Çalışmada katıksıklık ölçütü olarak, CART analizi çalışmalarında yaygın bir şekilde tercih edilen Gini indeksi kullanılmış ve kurulacak modelin eğitim setine aşırı uyum göstermesini engellemek üzere maliyet-karmaşık budama yöntemi kullanılmış ve ağacın yapraklarında minimum 2 vakanın olması şartları getirilmiştir. KS Testi ve CART ağacı SPSS 15.0 uygulaması kullanılarak gerçekleştirilmiştir.

3.4.2.1. Örnekleme Yöntemleri

Çalışma kapsamında örnekleme yöntemlerinden ‘bir tanesini dışarıda bırakma’ ve ‘10 bölmeli çapraz doğrulama’ ve ‘yerine koyma’ yöntemleri kullanılarak modelin performansı hakkında daha fazla bilgi edinilmeye çalışılmıştır. Rastgele örnekleme yöntemi özellikle de küçük veri setleriyle çalışıldığı durumlarda yanlı olabileceği düşüncesiyle tercih edilmezken, eğitim ve veri setinin aynı olduğu ‘yerine koyma’ yöntemi karşılaştırmalarda kullanılmak üzere gerçekleştirilmiştir. Üç farklı örnekleme yöntemiyle, yöntemler aralarındaki farklar görülmüş ve farklı çalışmalarla kıyaslanırken aynı örnekleme yöntemiyle ölçülen performansların karşılaştırılması sağlanmıştır.

3.4.2.2. Yanlış Sınıflandırma Maliyetleri

Önceki bölümlerde de ifade edildiği gibi finansal başarısızlığın öngörülmesi alanında Tip-II hatalar Tip-I hatalara oranla çok daha fazla maliyetlidir. Bu nedenle, bu alanda kurulacak olan modellerin değerlendirilmesinde sadece doğru sınıflandırma yüzdelerinin kullanılması çok doğru bir yaklaşım olarak görülmemektedir. Bununla birlikte, zaten az sayıda gözlem içeren veri setinde Tip-II ve Tip-I hata maliyetleri arasında gerçek dünyada var olan farkın modelin içerisine aynıyla aktarılması da, kurulacak modelde bütün bankaların finansal başarısız şeklinde sınıflandırılmasına yönelik bir meyil oluşturacağı açıktır. Bu sorun, Tip-II hata maliyeti Tip-I hata maliyetinin iki katı olacak şekilde modele dahil edilmesiyle aşılmaya çalışılmıştır.

3.4.2.3. Test Sonuçları

Bir Tanesini Dışarıda Bırakma Yöntemiyle Elde Edilen Sonuçlar:

Bu yöntemle gerçekleştirilen uygulama sonucunda elde edilen sınıflandırma tablosu Tablo 5’te, her bir bankaya ilişkin analiz sonuçlarını içeren ayrıntılı tablo ise Ek-2’de sunulmuştur.

Gözlemlenen	Tahmin Edilen		
	Başarısız Banka	Başarılı Banka	Doğru Sınıflandırma
Başarısız Banka	14	5	%73,68
Başarılı Banka	11	10	%47,61
Toplam	%62,50	%37,50	%60,0

Tablo 5 Bir tanesini dışarıda bırakma yöntemiyle elde edilen sonuçlar

Buna göre, modelin doğru sınıflandırma başarısı %60 olarak gerçekleşirken, finansal olarak başarısızlığa uğrayan bankaları ise %73,68 oranında doğru etmiştir.

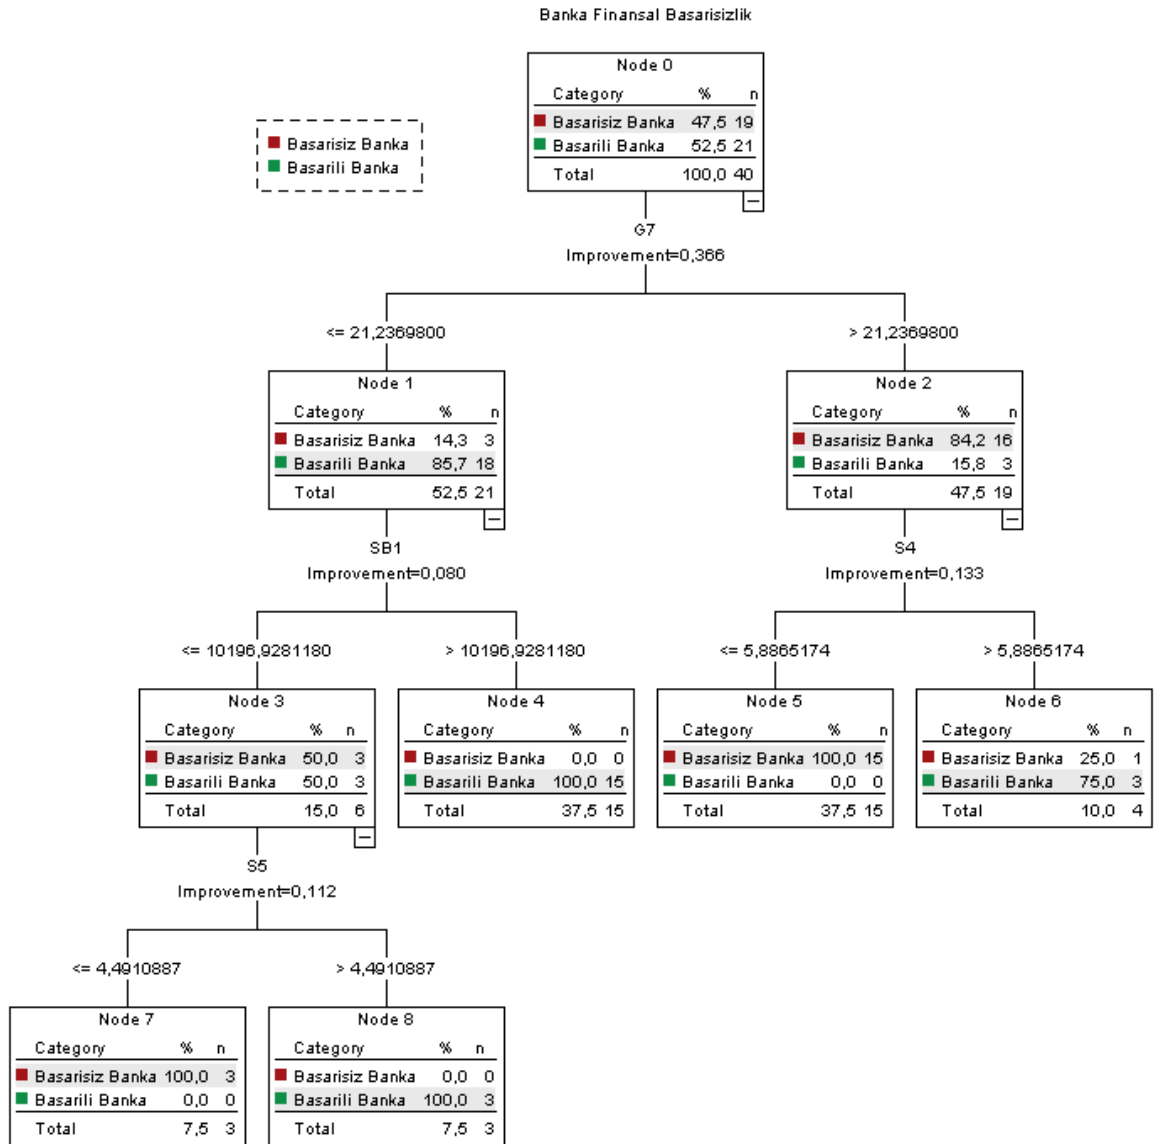
10 Bölmeli Çapraz Doğrulama Yöntemiyle Elde Edilen Sonuçlar

SPSS programında karar ağaçları için 10 bölmeli çapraz doğrulama seçeneği bulunmasına rağmen, araç kullanıldığında çapraz doğrulama sonucu elde edilen nihai ağaç ve çapraz doğrulama aşamalarında elde edilen doğru sınıflandırma oranı olarak kabul edilebilecek risk değerini vermektedir. Sınıflandırma tablosunu, elde edebilmek bankalar rastgele 10 gruba ayrılmış ve her defasında ayrı bir grup test seti olarak kullanılacak şekilde testler gerçekleştirilmiştir. Bu bölümde sunulan ağaç yapısı ise SPSS programı tarafından oluşturulan CART ağacını göstermektedir.

Gözlemlenen	Tahmin Edilen		
	Başarısız Banka	Başarılı Banka	Doğru Sınıflandırma
Başarısız Banka	15	4	78,95%
Başarılı Banka	8	13	61,90%
Toplam	57,5%	42,5%	70,0%

Tablo 6 10 bölmeli çapraz doğrulama yöntemiyle elde edilen sonuçlar

Tablo 6'da 10 bölmeli çapraz doğrulama sonucunda elde edilen sınıflandırma oranlarına yer verilmiştir. Şekil 7'de ise çapraz doğrulama sonucunda elde edilen ağaç yapısına yer verilmektedir.



Şekil 7 10 bölmeli çapraz doğrulama sonucu oluşturulan nihai ağaç yapısı

Yerine Koyma Yöntemiyle Elde Edilen Sonuçlar

Çapraz doğrulama sonucu oluşturulan ağaç yapısı veri setinin tamamının eğitim için kullanılmasıyla ortaya çıkmıştır. Bu ağacın aynı veri setinde yani 'yerine koyma' yöntemiyle test edilmesi sonucu elde edilen sonuçlara Tablo 7'de yer verilmektedir.

Söz konusu ağaç yapısında sadece Demirbank A.Ş. yalnız sınıflandırılmakta diğer bütün bankalar doğru bir şekilde sınıflandırılmaktadır. Bu noktadan bakıldığında oluşturulan nihai

ağaç, veri setinin %97,5'ini doğru sınıflandırırken finansal başarısızlığı %94,74 oranında doğru tahmin edebilmektedir. Bu yöntemle aynı veri seti hem eğitim hem de test için kullanılmıştır.

Gözlemlenen	Tahmin Edilen		
	Başarısız Banka	Başarılı Banka	Doğru Sınıflandırma
Başarısız Banka	18	1	94,7%
Başarılı Banka	0	21	100%
Toplam	45%	55%	97,5%

Tablo 7 Yerine koyma yöntemiyle elde edilen sonuçlar

3.4.3. CART Modelinin Karar Alma Sürecinin Değerlendirilmesi

Bu çalışmada, karar ağacı modelinin tercih edilmesinin en büyük nedenlerinden birisi, modelin karar alma sürecinin yorumlanabilir olmasıdır. 10 bölmeli çapraz doğrulama sonucunda oluşturulan ağaçtan finansal başarısızlığa ilişkin şu kurallar çıkartılabilmektedir:

- Eğer ([Faiz Giderleri/Ort. Getirili Aktifler] > 21,24 ve [Net Çalışma Sermayesi/Toplam Aktif] < 5,89) ise banka finansal başarısızlığa uğrayacaktır,
- Eğer ([Faiz Giderleri/Ort. Getirili Aktifler] ≤ 21,24] ve [Şube Başına Toplam Aktif] ≤ 10.197 ve [(Özkaynak+Top.Kar)/(Top.Aktif+Gayri Nakdi Krediler)] ≤ 4,49) ise banka finansal başarısızlığa uğrayacaktır.

Bu iki kural ile 1997-2001 yılları arasında finansal başarısızlığa uğramış olan 19 bankanın 18'i doğru bir şekilde sınıflandırılabilir. Yine aynı ağaç yapısından finansal başarısızlığa uğramamış bankalar için de kurallar çıkartılabilir.

Yukarıda ifade edilen kurallara bakıldığında, finansal başarısızlığa uğrayan bankaların en büyük ortak yönlerinin faiz giderlerinin, ortalama getirili aktiflere oranlara yükselmesi olduğu görülmektedir. Faiz giderleri belirli bir seviyenin üzerine çıkan bankalardan sadece sermaye yapısı güçlü olanlar yani net çalışma sermayesinin toplam aktifine oranı belirli bir seviyenin üstünde olanlar ayakta kalmayı başarabilmişlerdir. Bu durum, Kasım 2000 ve Şubat 2001 krizleri esnasında bankaların kur ve faiz yükselişlerine karşı oldukça duyarlı oldukları savını desteklemektedir (Özatay, 2009).

Faiz Giderleri/Ort.Getirili Aktifler oranını belirli bir seviyenin altında ve şube başına toplam aktifini de belli bir seviyenin üstüne tutabilen bankalar ise finansal başarısızlığa uğramamışlardır. Bu durum özetle, 1997-2001 döneminde bankaların faiz giderlerinin ciddi şekilde yükseldiğinin bu duruma sermaye yapısı güçlü olan bankaların direnç gösterebilirken gösteremeyen bankaların finansal başarısızlığa uğradığını göstermektedir. Bir diğer sonuç ise, şube başına daha fazla bankacılık faaliyetinde bulunabilen ve bu şekilde risklerini tabana yayabilen bankaların finansal başarısızlığa uğrama ihtimallerinin ciddi şekilde azaldığıdır.

3.5. MODELİN ÖNCEKİ ÇALIŞMALARLA KARŞILAŞTIRILMASI

CART ile gerçekleştirilen analiz geçmiş yıllarda yapılan çalışmalarla kıyaslanarak kurulan modelin performansının görece olarak değerlendirilebilmesi amaçlanmıştır. Bu kapsamda; Türkiye'ye ilişkin yapılan çalışmalardan hem dönem hem de seçilen bankalar açısından çalışmadaki kapsamla uyumlu olan iki makale tercih edilmiştir. Bu iki makaleden, Canbaş, Çabuk ve Kılıç (2005) ayrıştırma analizi, lojistik regresyon ve probit modellerini kullanılırken; Yıldız ve Akkoç (2009) ise sinirsel bulanık ağ yöntemini kullanmışlardır. Canbaş, Çabuk ve Kılıç (2005) tarafından yapılan çalışma, CART modelinin geleneksel istatistiksel modellerle kıyaslanabilmesi ve Yıldız ve Akkoç'un (2009) çalışması ise modellerin karar alma süreçlerinin karşılaştırılabilmesi açısından tercih edilmiştir.

Model Karşılaştırma (%)	Canbaş, Çabuk ve Kılıç (2005)			CART Modeli
	Ayrıştırma	Logit	Probit	
Doğru Sınıflandırma	90	87,5	87,5	97,5
Tip-I Hata	15	10	15	0
Tip-II Hata	5	5	5	5

Tablo 8 Canbaş, Çabuk ve Kılıç (2005) ve CART modeli sonuçlarının karşılaştırılması

Tablo 8'de CART modelinin, ayrıştırma analizi, Logit ve Probit modelleriyle olan karşılaştırmasına yer verilmiştir. Canbaş, Çabuk ve Kılıç çalışmalarında ayrı bir eğitim ve test seti kullanmamış, yerine koyma yöntemiyle elde ettikleri sonuçları paylaşmışlardır. Modellerin görece performanslarının ölçülebilmesi açısından bu sonuçlar CART modelinin yerine koyma yöntemiyle elde edilen sonuçlarıyla karşılaştırılmıştır. Tablodan görülebildiği üzere, CART modeli istatistiksel modellere nazaran çok daha iyi sınıflandırma oranları sunmaktadır.

Yıldız ve Akkoç (2009) ise sinirsel bulanık ağ modeliyle gerçekleştirdikleri çalışmalarında veri setinin %60'ını eğitim %40'ını ise test için ayırmışlardır. Veri setinin 40 bankadan oluştuğu bir çalışmada bu şekilde 16 banka üzerinden test gerçekleştirilmiştir. Küçük veri setlerinde rastgele örnekleme yöntemiyle gerçekleştirilen bu tür testler oldukça fazla yanılma paylarına sahip olduklarından dolayı bu çalışma kapsamında bu tarz bir test gerçekleştirilmemiştir. Bunun yerine, eğitim ve test setlerinin ayrı olduğu daha gerçekçi sonuçlar veren 10-bölmeli çapraz doğrulama yöntemiyle modelin öngörü performansı ölçülmeye çalışılmıştır. Tablo 9'da Yıldız ve Akkoç tarafından yapılan çalışmada test seti üzerinde gerçekleşen doğru sınıflandırma oranları ile CART modelinin 10-bölmeli çapraz doğrulama sonuçları karşılaştırılmalı olarak verilmiştir.

Model Karşılaştırma (%)	Sinirsel Bulanık Ağ Modeli Yıldız ve Akkoç (2009)	CART Modeli
Doğru Sınıflandırma	81	70
Tip-I Hata	33,3	38
Tip-II Hata	0	21

Tablo 9 Yıldız ve Akkoç (2009) ile CART modeli sonuçlarının karşılaştırılması

Tablodan görülebildiği üzere sinirsel bulanık ağ modeli, özellikle Tip-II hata anlamında çok başarılı sonuçlar vermiştir. Yalnız yukarıda da ifade edildiği gibi çalışmada kullanılan rastgele örnekleme yöntemiyle modelin gerçek performansının ölçülmesinin çok da mümkün olmayacağı düşünülmektedir.

Yıldız ve Akkoç (2009) sinirsel bulanık ağ modelinin;

- (Özkaynak + Toplam Kar)/(Mevd. +Mev. Dışı Kay.) (S3) oranının negatif olduğu
- Faiz Giderleri/Ort. Götürülü Aktifler (G6) oranının 20 değerinin üstüne çıktığı
- Şube Başına Kredi (SB6) değerinin 5 milyon değerinin altında olduğu

durumlarda bankanın finansal başarısızlığa uğrama olasılığının arttığını gözlemlemişlerdir.

Ana Düğüm	Bağımsız Değişkenler		Gelişim	İlişki
0	Asıl	G7	0,366	0,947
	Vekil	G6	0,315	
1	Asıl	SB1	0,08	0,667
	Vekil	SB6	0,047	
3	Asıl	S5	0,113	0,667
	Vekil	G6	0,056	
2	Asıl	S4	0,133	0,77
	Vekil	S1	0,061	

Tablo 10 CART modelinde yer alan düğümlerdeki asıl ve vekil değişkenler

Bilindiği üzere CART modelinde her bir düğüm için asıl ve vekil değişkenler belirlenmekte, veri setinde eksik değerler bulunması durumunda asıl değişkenlerle en yakın ilişki içerisinde olan vekil değişkenler kullanılarak bu sorun aşılmaktadır. Tablo 10, CART analizi sonucu modelde yer alan her bir asıl değişkeni vekilleriyle birlikte vermektedir. Bu tablodan da görülebildiği üzere CART modelinde G6, G7 değişkeninin ile SB6 ise SB1 değişkeninin vekilidir. Dolayısıyla bu değişkenler arasında ciddi bir ilişki bulunduğu modelde öngörülmüştür.

CART modelinin karar alma sürecine bakıldığında ise G7 değişkenin 21,24'ten büyük olduğu durumlarda finansal başarısızlığa uğrama olasılığının yüksek (16/19) olduğu, bu durumdan sadece Net Çalışma Sermayesi/Toplam Aktif (S4) oranı 5,8 den yüksek olan dolayısıyla sermaye yapısı güçlü olan bankaların muaf tutulduğu görülmektedir.

Aynı durum Yıldız ve Akkoç'un kullandığı Şube Başına Kredi (SB6) oranı için de geçerlidir. CART modelinde Şube Başına Toplam Aktif (SB1) oranı kullanılırken bu oranla en fazla ilişkili olan oran SB6 SB1'in vekili olarak belirlenmiştir. CART modelinde SB1 oranı 10.196'nın üzerinde olan bankalar finansal başarısızlığa uğramayan bankalar olarak sınıflandırılmıştır. Bu oranın 10.196'nın altında kaldığı durumlarda ise $(\text{Özkaynak} + \text{Top.Kar}) / (\text{Top.Aktif} + \text{Gayri Nakdi Krediler})$ (S5) oranı 4,5'un altında kalanlar finansal başarısızlığa uğrayan bankalar olarak sınıflandırılmışlardır.

Dolayısıyla her iki model de finansal başarısızlığa uğrayan bankaların, faiz giderlerinin aktiflerine (getirili/götürülü) oranlarının yükseldiğini ve şube başına düşen aktif veya kredi oranlarının yükselmesinin ise bankaların finansal başarısızlığa uğrama olasılıklarını

düşürdüğünü ortaya koymaktadır. Bu sonuçlarla, her iki modelin finansal başarısızlığa götüren sürece ilişkin benzer sonuçlar ortaya koyduğunu söylemek mümkündür.

SONUÇ VE DEĞERLENDİRME

Bu çalışmada, veri madenciliği ve örüntü tanıma yöntemlerinden biri olan karar ağaçlarıyla finansal başarısızlık öngörüsünde bulunulması ve bir erken uyarı sistemi geliştirilmesi hedeflenmiştir. Karar ağaçları, modelde değişkenlerin nasıl kullanıldığının ve ne şekilde karar alındığının yorumlanmasına olanak vermektedir. İstatiksel yöntemlerden farklı olarak değişkenlere ilişkin herhangi bir varsayımda bulunulmasına gerek olmaması, vekil değişken kullanarak eksik verilerle çalışılabilmesine olanak sağlaması ve görece az sayıda veriyle dahi çalışabilmesi karar ağaçlarının diğer güçlü yanlarındanır. Karar ağaçları bu avantajlarına rağmen finansal başarısızlık alanında çok fazla kullanım alanı bulamamıştır.

1997-2001 dönemleri içerisinde yaşanan banka finansal başarısızlıklarından elde edilen verilerle 10 yıl sonrası bir döneme ışık tutacak bir erken uyarı sisteminin ortaya konulması gelişen finansal piyasalar da göz önüne alındığında çok mümkün değildir. Bu nedenle çalışma sonucunda, yüksek öngörü başarısından daha ziyade modelin karar alma sürecinin analiz edilmesiyle finansal başarısızlığa götüren nedenlerin incelenmesi hedeflenmiştir. Ayrıca, Türkiye'ye ilişkin çalışmalarda şimdiye kadar hiç denenmemiş olan karar ağacı yönteminin önceki çalışmalarla karşılaştırılarak finansal başarısızlık öngörüsünde kullanılabilir bir yöntem olup olmadığı araştırılmıştır.

Çalışmada 1997-2001 dönemleri arasında finansal başarısızlığa uğrayarak TMSF'ye devredilen 19 bankanın bulunduğu toplam 40 bankaya ilişkin TBB'nin resmi internet sayfasından elde edilen finansal oranlar kullanılmıştır. Özellik seçimi yöntemi olarak, parametrik olmayan Kolmogorov-Smirnov (KS) testi ile finansal başarısız ve başarısız olmayan grup arasında ayrılmayan oranlar elenerek, modelin ilgisiz oranlardan arındırılması sağlanmıştır. Sonuçta elde edilen 19 finansal oran CART karar ağacına girdi olarak kullanılmıştır.

CART analizinin finansal başarısızlığın öngörüsündeki gerçek performansının öngörülebilmesi amacıyla 'bir tanesini dışarıda bırakma' ve '10 bölmeli çapraz doğrulama' yöntemleri kullanılmıştır. Elde edilen sonuçlar istatiksel yöntemlerin kullanıldığı Canbaş, Çabuk ve Kılıç (2005) ile modelin karar alma sürecinin incelenebildiği sinirsel bulanık ağ yönteminin kullanıldığı Yıldız ve Akkoç'un (2009) çalışmalarıyla karşılaştırılmıştır. Karşılaştırma sonuçları, karar ağaçlarının istatiksel yöntemlerden daha başarılı sonuçlar verebildiğini gösterirken, sinirsel bulanık ağ modeli karar ağacına nazaran daha başarılı bulunmuştur. CART

analizi ve sinirsel bulanık ağ modeli karar alma süreçleri ise birbirlerine oldukça yakın bulunmuştur.

Oluşturulan nihai karar ağacı yapısından çıkarılan 2 kural, finansal başarısızlığa uğramış olan 19 bankanın 18'i doğru bir şekilde sınıflandırılabilmiştir. Bu kurallara bakıldığında, finansal başarısızlığa uğrayan bankaların en büyük ortak yönlerinin faiz giderlerinin, ortalama getirili aktiflere oranlara yükselmesi olduğu görülmektedir. Faiz giderleri belirli bir seviyenin üzerine çıkan bankalardan sadece sermaye yapısı güçlü olanlar yani net çalışma sermayesinin toplam aktifine oranı belirli bir seviyenin üstünde olanlar ayakta kalmayı başarabilmişlerdir. *Faiz Giderleri/Ortalama Getirili Aktifler* oranını belirli bir seviyenin altında ve şube başına toplam aktifini de belli bir seviyenin üstüne tutabilen bankalar ise finansal başarısızlığa uğramamışlardır. Bu durum özetle, 1997-2001 döneminde bankaların faiz giderlerinin yükseldiğinin ve bu duruma sermaye yapısı güçlü olan bankaların direnç gösterebilirken gösteremeyen bankaların finansal başarısızlığa uğradığını göstermektedir.

EKLER

Ek-1: TBB Finansal Oranların Hesaplanmasında Kullanılan Formüller

Likit Aktifler = Nakit Değerler + Bankalar + Diğer Mali Kurumlar + Interbank + Menkul Değerler Cüzdanı + Mevd. Munz. Karşılık.

Ortalama Aktifler = (Toplam Aktifler(1.yıl) + Toplam Aktifler(2.yıl)) / 2

Ortalama Özkaynaklar = (Özkaynaklar(1.yıl) + Özkaynaklar(2.yıl)) / 2

Ortalama Ödenmiş Sermaye = (Ödenmiş Sermaye(1.yıl) + Ödenmiş Sermaye(2.yıl)) / 2

Mevduat Dışı Kaynaklar = Interbank + TCMB + Alınan Diğer Krediler + Fonlar + Çıkarılan Menkul Kıymetler

Gayrinakdi Krediler = Toplam Nazım Hesaplar - Diğer Nazım Hesaplar

Net Çalışma Sermayesi = Özkaynaklar + Toplam Kar - Bağlı Menkul Kıymetler hariç Duran Aktifler

Toplam Kar = Dönem Karı + Geçmiş Yıl Karları

Döviz Pozisyonu = YP Pasifler - YP Aktifler

Duran Aktifler = Takipteki Alacaklar + İştirakler + Bağlı Ortaklıklar + Bağlı Menkul Kıymetler + Sabit Kıymetler

Getirili Aktifler = Krediler + Menkul Değerler Cüzdanı + Bankalar + Interbank + KYAK Dev.Tah.Hes.

Götürülü Aktifler = Mevduat + Mevduat Dışı Kaynaklar

Toplam Gelirler = Faiz Gelirleri + Faiz Dışı Gelirler

Toplam Giderler = Faiz Giderleri + Faiz Dışı Giderler

Faiz Gelirleri = Kredilerden Alınan Faiz + Menkul Değerler Cüzdanı + Bankalardan + Interbank + Diğer Faiz Gelirleri

Diğer Faiz Gelirleri = Mevduat Munzam Karşılıklarından + Diğer

Faiz Giderleri = Mevduata Verilen Faiz + Kullanılan Kredilere Verilen Faiz + Diğer Faiz Giderleri

Diğer Faiz Giderleri = Interbanka Verilen Faizler + Çıkarılan Menkul Kıymetlere Verilen Faiz + Diğer

Takipteki Alacaklar Sonrası Net Faiz Geliri = Faiz Gelirleri - Faiz Giderleri - Takipteki Alacaklar Provizyonu

Faiz Dışı Gelirler = Komisyon Gelirleri (net) + Kambiyo Gelirleri (net) + Sermaye Piyasası İşlem Gelirleri(net) + Diğer

Komisyon Gelirleri (net) = Alınan Ücret ve Komisyonlar - Verilen Ücret ve Komisyonlar

Kambiyo Gelirleri (net) = Kambiyo Karları - Kambiyo Zararları

Sermaye Piyasası İşlem Gelirleri(net) = Sermaye Piyasası İşlem Karları - Sermaye Piyasası İşlem Zararları

Diğer Faiz Dışı Gelirler = İştirak ve Bağlı Ortaklıklardan Alınan Kar Payları + Olağanüstü Gelirler + Diğer

Faiz Dışı Giderler = Personel + Kıdem Tazminatı + Diğer Provizyonlar + Vergi ve Harçlar + Kira + Amortisman + Diğer

Diğer Faiz Dışı Giderler = Olağanüstü Giderler + Diğer

Faaliyet Giderleri = Personel Giderleri + Kıdem Tazminatı + Amortisman + Kira

Ayrılan Provizyonlar = Kıdem Tazminatı Provizyonu + Takipteki Alacaklar Provizyonu + Vergi Provizyonu + Diğer Provizyonlar

Vergi Öncesi Kar = Takipteki Alacak Sonrası Net Faiz Geliri + Faiz Dışı Gelirler - Faiz Dışı Giderler

Net Kar = Vergi Öncesi Kar - Vergi Provizyonu

Ek-2: Bir Tanesini Dışarıda Bırakma Yöntemiyle Elde Edilen Sonuçlar

Bankalar	Gerçek Durum	Tahmin Edilen
Adabank A.Ş.	Başarılı	Başarısız
Akbank T.A.Ş.	Başarılı	Başarılı
Alternatif Bank A.Ş.	Başarılı	Başarılı
Anadolubank A.Ş.	Başarılı	Başarısız
Bank Ekspres A.Ş.	Başarısız	Başarılı
Bank Kapital Türk A.Ş.	Başarısız	Başarısız
Bayındırbank A.Ş.	Başarısız	Başarılı
Birleşik Türk Körfez Bankası A.Ş.	Başarılı	Başarısız
Demirbank T.A.Ş.	Başarısız	Başarılı
Denizbank A.Ş.	Başarılı	Başarılı
Ege Giyim Sanayicileri Bankası A.Ş.	Başarısız	Başarısız
Egebank A.Ş.	Başarısız	Başarılı
Eskişehir Bankası T.A.Ş.	Başarısız	Başarısız
Etibank A.Ş.	Başarısız	Başarısız
Fiba Bank A.Ş.	Başarılı	Başarılı
Finans Bank A.Ş.	Başarılı	Başarısız
Interbank	Başarısız	Başarısız
İktisat Bankası T.A.Ş.	Başarısız	Başarısız
Kentbank A.Ş.	Başarısız	Başarılı
Koçbank A.Ş.	Başarılı	Başarısız
Milli Aydın Bankası T.A.Ş.	Başarısız	Başarısız
MNG Bank A.Ş.	Başarılı	Başarılı
Oyak Bank A.Ş.	Başarılı	Başarılı
Pamukbank T.A.Ş.	Başarılı	Başarısız
Sitebank A.Ş.	Başarısız	Başarısız
Sümerbank A.Ş.	Başarısız	Başarısız
Şekerbank T.A.Ş.	Başarılı	Başarısız
Tekstil Bankası A.Ş.	Başarılı	Başarılı
Toprakbank A.Ş.	Başarısız	Başarısız
Turkish Bank A.Ş.	Başarılı	Başarısız
Türk Dış Ticaret Bankası A.Ş.	Başarılı	Başarısız
Türk Ekonomi Bankası A.Ş.	Başarılı	Başarısız
Türk Ticaret Bankası A.Ş.	Başarısız	Başarısız
Türkiye Garanti Bankası A.Ş.	Başarılı	Başarılı
Türkiye İmar Bankası T.A.Ş.	Başarılı	Başarısız
Türkiye İş Bankası A.Ş.	Başarılı	Başarılı
Türkiye Tütüncüler Bankası Yaşarbank A.Ş.	Başarısız	Başarısız
Ulusal Bank T.A.Ş.	Başarısız	Başarısız
Yapı ve Kredi Bankası A.Ş.	Başarılı	Başarılı
Yurt Ticaret ve Kredi Bankası A.Ş.	Başarısız	Başarısız

Ek-3: TBS'ne Yönelik Yapılan Çalışmalarda Kullanılan Finansal Oranlar

Grup	Oranlar (Türkçe)	2005 Canbas, Cabuk,Kilic	2005, Benli	2006 Kilic	2007 Karababey	2008 Ravi, Pramodh	2009 Yildiz, Akkoç	2009 Chauhan, Ravi, Chandra	2009 Celikylimaz, Turksen,	2009 Boyacioglu, Kara, Baykan	2010 Ravisankar, Ravi	Toplam Seçim Sayısı	Kolmogorov Smirnov
Sermaye	Sermaye Standart Rasyosu		+		+			+			+	4	+
	(Özkaynak+Kar)/Toplam Aktif	+	+	+	+	+		+				6	+
	(Özkaynak+Top. Kar)/(Mev.+Mev.Dışı Kay.)	+	+	+	+	+	+	+			+	8	+
	Net Çalışma Sermayesi/Toplam Aktif	+	+	+	+	+		+				6	+
	(Özkaynak+Top.Kar)/(Top.Aktif+Gayri Nakdi Krediler)	+	+				+				+	4	+
	Döviz Pozisyonu/Özkaynak								+			1	
Likidite	Likit Aktifler/T.Aktifler	+	+	+	+						+	5	
	Likit Aktifler/(Mevduat + Mev.Dışı Kay.)		+		+	+		+	+		++	7	+
	YP Likit Aktifler/YP Pasifler											0	
Aktif Kalitesi	Top. Kredi/Top. Aktif											0	
	Takipteki krediler/Top. Krediler											0	
	Duran Aktifler/Top. Aktifler											0	
	YP Aktifler/YP Pasifler							+	+			2	
Faaliyet Rasyoları	(Personel Gideri+Kıdem Tazminatı)/T.Aktif											0	
	(Personel Gideri+Kıdem Tazm.)/Personel Sayısı (Milyar TL)	+	+								++	4	
	Kıdem Tazminatı/Personel Sayısı (Milyar TL)											0	
	Faaliyet Gideri/T.Aktif											0	
	Vergi Hariç Ayrılan Provizyonlar/T.Gelirler											0	+
	Vergi Dahil Ayrılan Provizyonlar/T.Gelirler								+			1	
Gelir-Gider Yapısı	Takip.Alac.Son.Net Faiz Gel./Ort.T.Aktif.											0	
	Faiz Gelirleri/Faiz Giderleri	+	+	+	+	+			+		+	7	+
	Faiz Dışı Gelirler/Faiz Dışı Giderler											0	
	Toplam Gelirler/Toplam Giderler			+	+				+			3	+
	Faiz Gelirleri/Ort. Getirili Aktifler				+							1	+
	Faiz Giderleri/Ort.Götürülü Aktifler	+	+		+		+				+	5	+
	Faiz Giderleri/Ort.Getirili Aktifler	+	+		+	+			+		++	7	+

KAYNAKÇA

- Ađır, H., Peker, O., ve Kar, M. (2009). Finansal Gelişmenin Belirleyicileri Üzerine Bir Deđerlendirme: Literatür Taraması. *BDDK Bankacılık ve Finansal Piyasalar Dergisi* , 3 (2), 31-62.
- Ahn, H., ve Kim, K.-j. (2009). Bankruptcy prediction modeling with hybrid case-based reasoning and genetic algorithms approach. *Applied Soft Computing* , 9, 599–607.
- Aktaş, D. R., Dođanay, D. M., ve Yıldız, Y. D. (2003). Mali Başarısızlığın Öngörülmesi: İstatiksel Yöntemler ve Yapay Sinir Ađı Karşılaştırması. *Ankara Üniversitesi SBF Dergisi* .
- Aktaş, R. (1997). *Mali Başarısızlık (İşletme Riski) Tahmin Modelleri*. Ankara: Türkiye İş Bankası Kültür Yayınları.
- Alam, P., Booth, D., Lee, K., ve Thordarson, T. (2000). The use of fuzzy clustering algorithm and self-organizing neural networks for identifying potentially failing banks: an experimental study. *Expert Systems with Applications* , 18 (3), 185-199.
- Albayrak, A. S. (2009). Türkiye'de Yerli ve Yabancı Ticaret Bankalarının Finansal Etkinliğine Göre Sınıflandırılması: Karar Ađacı, Lojistik Regresyon ve Diskriminant Analizi Modellerinin Bir Karşılaştırması. *Süleyman Demirel Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi* , 14 (2), 113-139.
- Altman, E. I. (1968). Financial ratios, discriminant analysis and the prediction of corporate bankruptcy. *The Journal of Finance* , 23 (4), 589-609.
- Andrés, J. D., Lorca, P., Juez, F. J., ve Sánchez-Lasheras, F. (2011). Bankruptcy forecasting: A hybrid approach using Fuzzy c-means clustering and Multivariate Adaptive Regression Splines (MARS). *Expert Systems with Applications* , 38, 1866–1875.
- Ballı, S., Uđur, A., ve Korukođlu, S. (2009). İnsan Kaynakları Yönetiminde Performans Deđerlendirme İçin Bir Bulanık Uzman Sistem Gerçekleştirimi. *Ege Akademik Bakış* , 9 (2), 837-849.
- Ban, Ü., ve Mazıbaş, M. (2009). Banka başarısızlıklarının yapay sinir ađlarıyla tahmini: Türk bankacılık sistemi üzerine karşılaştırmalı bir uygulama. *İktisat İşletme ve Finans* , 24 (282), 27-53.

- BDDK. (2003). *Bankacılık Sektörü Yeniden Yapılandırma Programı Gelişme Raporu (VII)*. Ankara: Bankacılık Düzenleme ve Denetleme Kurumu.
- BDDK. (2011). *Finansal Piyasalar Raporu*. Ankara: Bankacılık Düzenleme ve Denetleme Kurumu.
- BDDK. (2009). *Krizden İstikrara Türkiye Tecrübesi*. Ankara: Bankacılık Düzenleme ve Denetleme Kurumu.
- Beaver, W. H. (1966). Financial Ratios As Predictors of Failure. *Journal of Accounting Research* , 4, 71-111.
- Benli, Y. K. (2005). Bankalarda Mali Başarısızlığın Öngörülmesi Lojistik Regresyon Ve Yapay Sinir Ağı Karşılaştırması. *Gazi Üniversitesi Endüstriyel Sanatlar Eğitim Fakültesi Dergisi* , 16, 31-46.
- Berenji, H., Wang, Y., ve Saxena, A. (2005). Dynamic Case Based Reasoning in Fault Diagnosis and Prognosis. *Fuzzy Systems, 2005. FUZZ '05. The 14th IEEE International Conference*, (s. 845 - 850). Reno, NV .
- Bircan, H., Karagöz, Y., ve Kasapoğlu, Y. (2003). Ki-Kare Ve Kolmogorov Smirnov Uygunluk Testlerinin Simulasyon İle Elde Edilen Veriler Üzerinde Karşılaştırılması. *C.Ü. İktisadi ve İdari Bilimler Dergisi* , 4 (1), 69-80.
- Boyacioglu, M. A., Kara, Y., ve Baykan, Ö. K. (2009). Predicting bank financial failures using neural networks, support vector machines and multivariate statistical methods: A comparative analysis in the sample of savings deposit insurance fund (SDIF) transferred banks in Turkey. *Expert Systems with Applications* , 36, 3355–3366.
- Bryant, S. M. (1997). A case-based reasoning approach to bankruptcy prediction modeling. *Intelligent Systems in Accounting, Finance & Management* , 6 (3), 195-214.
- Canbas, S., Cabuk, A., ve Kilic, S. B. (2005). Prediction of commercial bank failure via multivariate statistical analysis of financial structures: The Turkish case. *European Journal of Operational Research* , 166 (2), 528-546.
- Canbas, S., Cabuk, A., ve Kilic, S. B. (2005). Prediction of commercial bank failure via multivariate statistical analysis of financial structures: The Turkish case. *European Journal of Operational Research* , 166, 528–546.
- Celikyilmaz, A., Türksen, I. B., Aktaş, R., Doganay, M. M., ve Ceylan, N. B. (2009). Increasing accuracy of two-class pattern recognition with enhanced fuzzy functions. *Expert Systems with Applications* , 36, 1337–1354.
- Chaudhuri, A., ve De, K. (2011). Fuzzy Support Vector Machine for bankruptcy prediction. *Applied Soft Computing* , 11, 2472–2486.

- Chauhan, N., Ravi, V., ve Chandra, D. K. (2009). Differential evolution trained wavelet neural networks: Application to bankruptcy prediction in banks. *Expert Systems with Applications* , 36, 7659–7665.
- Chen, H.-J., Huang, S. Y., ve Lin, C.-S. (2009). Alternative diagnosis of corporate bankruptcy: A neuro fuzzy approach. *Expert Systems with Applications* , 36, 7710–7720.
- Chen, M.-Y. (2011). Predicting corporate financial distress based on integration of decision tree classification and logistic regression. *Expert Systems with Applications* , *In Press*, *Corrected Proof*.
- Chen, W.-S., ve Du, Y.-K. (2009). Using neural networks and data mining techniques for the financial distress prediction model. *Expert Systems with Applications* , 36, 4075–4086.
- Cheng, J.-H., Yeh, C.-H., ve Chiu, Y.-W. (2007). Improving Business Failure Predication Using Rough Sets with Non-financial Variables. B. Beliczynski, A. Dzielinski, M. Iwanowski, ve B. Ribeiro içinde, *Adaptive and Natural Computing Algorithms* (Cilt 4431, s. 614-621). Adaptive and Natural Computing Algorithms.
- Cielen, A., Peeters, L., ve Vanhoof, K. (2004). Bankruptcy prediction using a data envelopment analysis. *European Journal of Operational Research* , 154 (2), 526-532.
- Cole, R. A., ve Gunther, J. (1995). A CAMEL Rating's Shelf Life . *Federal Reserve Bank of Dallas Review* , 13-20.
- Çinko, M., ve Avcı, E. (2008). CAMELS Derecelendirme Sistemi ve Türk Ticari Bankalar Sektöründe Başarısızlık Tahmini. *BDDK Bankacılık ve Finansal Piyasalar* , 2 (2), 25-48.
- Deakin, E. B. (1972). A Discriminant Analysis of Predictors of Business Failure. *Journal of Accounting Research* , 10, 167-179.
- Deakin, E. B. (1976). Distributions of financial accounting ratios: some empirical evidence. *The Accounting Review* , 51 (1), 90-96.
- Demir, Y., ve Astarçioğlu, M. (2007). Finansal tahmin yoluyla banka performansının belirlenmesi: İMKB'de bir uygulama. *Süleyman Demirel Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi* , 12 (1), 273-292.
- Demyanyk, Y., ve Hasan, I. (2010). Financial crises and bank failures: A review of prediction methods. *Omega* , 38, 315–324.
- Eibe, S., Del Saz, R., Fernández, C., Marbán, Ó., Menasalvas, E., ve Pérez, C. (2005). Financial Risk Prediction Using Rough Sets Tools: A Case Study. In D. Slezak, J. Yao, J. F. Peters, W. Ziarko, ve X. Hu, *Rough Sets, Fuzzy Sets, Data Mining, and Granular Computing* (Vol. 3642, pp. 495-502). Springer Berlin / Heidelberg.
- Ekinci, A., ve Erdal, H. İ. (2011). Türkiye’de banka başarısızlıklarının tahmini üzerine bir uygulama. *İktisat, İşletme ve Finans* , 26 (298), 21-44.

- Er, H., Çetin, M. K., ve Çetin, E. İ. (2005). Finansta Evrimsel Algoritmik Yaklaşımlar: Genetik Algoritma Uygulamaları. *Akdeniz İ.İ.B.F. Dergisi* , 10, 73-94.
- Erden, L., Özkan, İ., ve Günalp, B. (2009). What Do Productivity Shocks Tell Us About The Saving-Investment Relationship? *PRAGUE ECONOMIC PAPERS* , 3, 195-208.
- FDIC. (2011). *FDIC: Failed Bank List*. Haziran 6, 2011 tarihinde <http://www.fdic.gov/bank/individual/failed/banklist.html> adresinden alındı
- Fethi, M. D., ve Pasiouras, F. (2010). Assessing bank efficiency and performance with operational research and artificial intelligence techniques: A survey. *European Journal of Operational Research* , 204, 189–198.
- Frydman, H., Altman, E. I., ve Kao, D.-L. (1985). Introducing Recursive Partitioning for Financial Classification: The Case of Financial Distress. *The Journal of Finance* , 40 (1), 269-291.
- Gentry, J. A., Newbold, P., ve Whitford, D. T. (1987). Funds Flow Components, Financial Ratios, and Bankruptcy. *Journal of Business Finance & Accounting* , 25 (5), 595-606.
- Gentry, J. A., Whitford, D. T., ve Newbold, P. (1985). Classifying Bankrupt Firms with Fund Flow Components. *Journal of Accounting Research* , 23, 146-160.
- Greco, S., Matarazzo, B., ve Slowinski, R. (1998). A new rough set approach to evaluation of bankruptcy risk. C. Zopounidis içinde, *Operational Tools in the Management of Financial Risks* (s. 121–136). Dordrecht: Kluwer Academic Publishers.
- Grice, J. S., ve Ingram, R. W. (2001). Tests of the generalizability of Altman's bankruptcy prediction model. *Journal of Business Research* , 54 (1), 53-61.
- Huang, S.-M., Tsai, C.-F., Yen, D. C., ve Cheng, Y.-L. (2008). A hybrid financial analysis model for business failure prediction. *Expert Systems with Applications* , 35, 1034–1040.
- IMF. (2010). *World Economic Outlook: Recovery, Risk and Rebalancing*. Washington, D.C.: International Monetary Fund.
- Ioannidis, C., Pasiouras, F., & Zopounidis, C. (2010). Assessing bank soundness with classification techniques. *Omega* , 38, 345–357.
- Jo, H., Han, I. ve Lee, H. (1997). Bankruptcy prediction using case-based reasoning, neural networks, and discriminant analysis. *Expert Systems with Applications* , 13 (2), 97-108.
- Kao, C. ve Liu, S.-T. (2004). Predicting bank performance with financial forecasts: A case of Taiwan commercial banks. *Journal of Banking & Finance* , 28, 2353–2368.
- Karacabey, A. A. (2007). Bank Failure Prediction Using Modified Minimum Deviation Model. *International Research Journal of Finance and Economics* (12), 147-159.
- Kaya, Y. T. (2001). *Türk Bankacılık Sektöründe CAMELS Analizi*. Ankara: Bankacılık Düzenleme ve Denetleme Kurumu.

- Kılıç, S. B. (2006). Türk bankacılık sistemi için çok kriterli karar alma analizine dayalı bir erken uyarı modelinin tahmini. *ODTÜ Gelişme Dergisi* , 33, 117-154.
- Kocamaz, M. ve Çiçekli, U. G. (2010). Paralel Makinaların Genetik Algoritma İle Çizelgelenmesinde Mutasyon Oranının Etkinliği. *Ege Akademik Bakış* , 10 (1), 199-210.
- Kumar, P. R. ve Ravi, V. (2007). Bankruptcy prediction in banks and firms via statistical and intelligent techniques – A review. *European Journal of Operational Research* , 180 (1), 1-28.
- Laeven, L. ve Valencia, F. (2008). *Systemic Banking Crises: A New Database*. International Money Found.
- Lanine, G. ve Vennet, R. V. (2006). Failure prediction in the Russian bank sector with logit and trait recognition models. *Expert Systems with Applications* , 300 (3), 463-478.
- Lee, K. C., Han, I. ve Kwon, Y. (1996). Hybrid neural network models for bankruptcy predictions. *Decision Support Systems* , 18 (1), 63-72.
- Lee, K., Booth, D. ve Alam, P. (2005). A comparison of supervised and unsupervised neural networks in predicting bankruptcy of Korean firms. *Expert Systems with Applications* , 29 (1), 1-16.
- Leshno, M. ve Spector, Y. (1996). Neural network prediction analysis: The bankruptcy case. *Neurocomputing* , 10 (2), 125-147.
- Li, H. ve Sun, J. (2011). Empirical research of hybridizing principal component analysis with multivariate discriminant analysis and logistic regression for business failure prediction. *Expert Systems with Applications* , 38 (5), 6244-6253.
- Li, H. ve Sun, J. (2011). Predicting business failure using forward ranking-order case-based reasoning. *Expert Systems with Applications* , 38 (4), 3075-3084.
- Li, H. ve Sun, J. (2008). Ranking-order case-based reasoning for financial distress prediction. *Knowledge-Based Systems* , 21, 868–878.
- Li, H., Sun, J. ve Wu, J. (2010). Predicting business failure using classification and regression tree: An empirical comparison with popular classical statistical methods and top classification mining methods. *Expert Systems with Applications* , 37, 5895–5904.
- Liu, H. ve Motoda, H. (2008). *Computational Methods of Feature Selection*. Boca Raton: Chapman & Hall/CRC.
- Luo, X. (2003). Evaluating the profitability and marketability efficiency of large banks: An application of data envelopment analysis. *Journal of Business Research* , 56 (8), 627-635.
- Maimon, O. ve Rokach, L. (2010). *Data Mining and Knowledge Discovery Handbook*. Tel-Aviv: Springer.

- Marais, M. L., Patell, J. M. ve Wolfson, M. A. (1984). The Experimental Design of Classification Models: An Application of Recursive Partitioning and Bootstrapping to Commercial Bank Loan Classifications. *Journal of Accounting Research* , 22, 87-114.
- McKee, T. E. (2000). Developing a bankruptcy prediction model via rough sets theory. *International Journal of Intelligent Systems in Accounting, Finance & Management* , 9 (3), 159-173(15).
- McKee, T. E. (2003). Rough sets bankruptcy prediction models versus auditor signalling rates. *Journal of Forecasting* , 22 (8), 569-586.
- Meyer, P. A. ve Pifer, H. W. (1970). Prediction of Bank Failures. *The Journal of Finance* , 25, 853-868.
- Min, J. H. ve Lee, Y.-C. (2005). Bankruptcy prediction using support vector machine with optimal choice of kernel function parameters. *Expert Systems with Applications* , 28 (4), 603-614.
- Nguyen, M., Shi, D. ve Quek, C. (2008). A nature inspired Ying–Yang approach for intelligent decision support in bank solvency analysis. *Expert Systems with Applications* , 34, 2576–2587.
- Oğuzlar, A. (2004). CART Analizi ile Hanehalkı İşgücü Anketi Sonuçlarının Özetlenmesi. *Atatürk Üniversitesi İİBF Dergisi* , 18 , 79-90.
- Ohlson, J. A. (1980). Financial Ratios and the Probabilistic Prediction of Bankruptcy. *Journal of Accounting Research* , 18, 109-131.
- Özatay, F. (2009). *Finansal Krizler ve Türkiye*. İstanbul: Doğan Kitap.
- Pawlak, Z. (1982). Rough sets. *International Journal of Parallel Programming* , 11 (5), 341-356.
- Pham, H. (2006). Classification and Regression Tree (CART). H. Pham içinde, *Springer Handbook of Engineering Statistics* (s. 555-560). Springer.
- Piramuthu, S., Ragavan, H. ve Shaw, M. J. (1998). Using feature construction to improve the performance of the neural networks. *Management Science* , 44 (3), 416-430.
- Ravi, V. ve Pramodh, C. (2008). Threshold accepting trained principal component neural network and feature subset selection: Application to bankruptcy prediction in banks. *Applied Soft Computing* , 8, 1539–1548.
- Ravi, V. ve Ravisankar, P. (2010). Financial distress prediction in banks using Group Method of Data Handling neural network, counter propagation neural network and fuzzy ARTMAP. *Knowledge-Based Systems* , 23 (8), 823-831.

- Ravisankar, P. ve Ravi, V. (2010). Financial distress prediction in banks using Group Method of Data Handling neural network, counter propagation neural network and fuzzy ARTMAP. *Knowledge-Based Systems* , 23, 823–831.
- Rokach, L. ve Maimon, O. (2008). *Data Mining with Decision Trees*. Singapore: World Scientific Publishing Co. Pte. Ltd.
- Seyrek, İ. H. ve Ata, H. A. (2010). Veri Zarflama Analizi ve Veri Madenciliği ile Mevduat Bankalarında Etkinlik Ölçümü. *BDDK Bankacılık ve Finansal Piyasalar Dergisi* , 4 (2), 67-84.
- Seyrek, İ. H. ve Ata, H. (2010). Veri Zarflama Analizi ve Veri Madenciliği ile Mevduat Bankalarında Etkinlik Ölçümü. *BDDK Bankacılık ve Finansal Piyasalar Dergisi* , 4 (2), 67-84.
- Sharda, R. ve Wilson, R. L. (1993). Performance Comparison Issues in Neural Network Experiments for Classification Problems. *System Sciences, 1993, Proceeding of the Twenty-Sixth Hawaii International Conference on* , 4, 649 - 657.
- Shin, K.-S. ve Lee, Y.-J. (2002). A genetic algorithm application in bankruptcy prediction modeling. *Expert Systems with Applications* , 23 (3), 321-328.
- Shin, S., Lee, K. ve Kilic, S. (2006). Ensemble Prediction of Commercial Bank Failure Through Diversification of Input Features. A. Sattar içinde, *AI 2006: Advances in Artificial Intelligence* (Cilt 4304, s. 887-896). Springer Berlin / Heidelberg.
- Sinkey, J. F. (1975). A Multivariate Statistical Analysis of the Characteristics of Problem Banks. *The Journal of Finance* , 30, 21-36.
- Slowinski, R. (1995). Rough set approach to decision analysis. *AI Expert* , 19-25.
- So, J. C. (1987). Some Empirical Evidence on the Outliers and the Non-normal Distribution of Financial Ratios. *Journal of Business Finance & Accounting* , 483-496.
- Soman, K., Diwakar, S. ve Ajay, V. (2006). *Insight into Data Mining: Theory and Practice*. Prentice-Hall of India Pvt.Ltd.
- Swicegood, P. ve Clark, J. A. (2001). Off-site Monitoring Systems for Predicting Bank Underperformance: A Comparison of Neural Networks, Discriminant Analysis, and Professional Human Judgment. *Intelligent Systems in Accounting, Finance & Management* , 10 (3), 169-186.
- Taha, H. A. (2000). *Yöneylem Araştırması*. İstanbul: Literatür Yayıncılık.
- Tam, K. Y. ve Kiang, M. Y. (1992). Managerial Applications of Neural Networks: The Case of Bank Failure Predictions. *Management Science* , 38 (7), 926-947.

- TMSF. (2011). Haziran 1, 2011 tarihinde http://www.tmsf.org.tr/index.cfm?fuseaction=public.dsp_menu_content&menu_id=22 adresinden alındı
- Tsai, C.-F. (2009). Feature selection in bankruptcy prediction. *Knowledge-Based Systems* , 120–127.
- Tunay, K. B. (2010). Bankacılık Krizleri ve Erken Uyarı Sistemleri: Türk Bankacılık Sektörü İçin Bir Model Uyarısı. *BDDK Bankacılık ve Finansal Piyasalar Dergisi* , 4 (1), 9-46.
- Uygur, E. (2001). *Krizden Krize Türkiye: 2000 Kasım ve 2001 Şubat Krizleri*. Ankara: Türkiye Ekonomi Kurumu.
- Varetto, F. (1998). Genetic algorithms applications in the analysis of insolvency risk. *Journal of Banking & Finance* , 22 (10-11), 1421-1439.
- Wilson, R. L. ve Sharda, R. (1994). Bankruptcy prediction using neural networks. *Decision Support Systems* , 11 (5), 545-557.
- Yang, Z. R., Platt, M. B. ve Platt, H. D. (1999). Probabilistic Neural Networks in Bankruptcy Prediction. *Journal of Business Research* , 44 (2), 67-74.
- Yıldız, B. ve Akkoç, S. (2009). Banka Finansal Başarısızlıklarının Sinirsel Bulanık Ağ Yöntemi ile Öngörüsü. *BDDK Bankacılık ve Finansal Piyasalar Dergisi* .
- Zhao, H., Sinha, A. P. ve Ge, W. (2009). Effects of feature construction on classification performance: An empirical study in bank failure prediction. *Expert Systems with Applications* (36), 2633–2644.