

## TÜRK BANKACILIK SEKTÖRÜNDE FİNANSAL GÜÇ DERECELERİNİN TAHMİNİNDE YAPAY SINIR AĞLARI VE ÇOK DEĞİŞKENLİ İSTATİSTİKSEL ANALİZ TEKNİKLERİNİN PERFORMANSLARININ KARŞILAŞTIRILMASI

Melek ACAR BOYACIOĞLU\*

Yakup KARA\*\*

### ÖZET

*Finansal güç derecelendirmesi (financial strength rating), bir bankanın temel finansal gücünü gösterir. Burada amaçlanan bir bankanın temel finansal gücünün dış faktörlerin değerlendirme harici bırakılması suretiyle ölçülmesidir. Dış faktörler, bankanın faaliyet çevresinden kaynaklanabileceği gibi, koruyucu nitelikteki dış destek mekanizmalarının varlığı ile de bağlantılı olabilir. Yapılan değerlendirme ile bankanın, koruyucu dış faktörlerden tamamen arındırılmış derecelendirmesi nasıl olurdu sorusuna cevap aranır. Ayrıca bu değerlendirmede bankanın finansal temeli, şube ağının gücü, faaliyet alanlarındaki ve varlıklarındaki çeşitlilik incelenir.*

*Bu çalışmada Türk bankalarının finansal güç derecelerini yapay sınır ağları ve çok değişkenli istatistiksel analiz teknikleri kullanarak tahmin etmek amacıyla bir model geliştirilmiştir. Çalışmanın metodolojisi, modelde yer alan değişkenlerin seçilmesi, veri setinin oluşturulması, kullanılacak tekniklerin belirlenmesi ve bu tekniklerin doğru sınıflandırma başarısının değerlendirilmesinden oluşmaktadır. Yapay sınır ağı, modelin elde edildiği veri setinde çok değişkenli istatistiksel analiz teknikleri ne göre yüksek bir sınıflandırma performansı göstermiştir. Modelin geçerliliğinin test edildiği veri setinde ise kullanılan tekniklerin tahmin performansları arasında anlamlı bir fark bulunamamıştır.*

*Anahtar kelimeler: Bankalar, Finansal Güç Derecelendirmesi, Yapay Sınır Ağları, Çok Değişkenli İstatistiksel Analiz Teknikleri.*

### 1. Giriş

Banka finansal güç derecelendirmesi (BFGD), özellikle yatırımcılara ve sınır ötesi bankalar arası kredi verenlere, bankanın finansal açıdan yapısal güvenilirliği ve sağlamlığı hakkında kurumsal ölçekte bilgi verir. BFGD bir bankanın sermaye yeterliliğini ve varlıklarının kalitesini değerlendirir. Bu inceleme esas itibarıyla, kredi portföyünün zarar yapısını veya pay sahipliğinden kaynaklanan kayıpları da kapsar. BFGD banka stratejileri ve risk denetim mekanizmaları hakkında sorular yöneltmek üzere yönetimin profesyonelliğini

\* Yrd.Doç.Dr., Selçuk Üniversitesi, İktisadi ve İdari Bilimler Fakültesi, İşletme Bölümü, ([melekacar@yahoo.com](mailto:melekacar@yahoo.com)).

\*\* Yrd.Doç.Dr., Selçuk Üniversitesi, Mühendislik-Mimarlık Fakültesi, Endüstri Mühendisliği Bölümü, ([ykara@selcuk.edu.tr](mailto:ykara@selcuk.edu.tr)).

ölçmeye çalışır. Ayrıca bankanın karlılığı ve şube ađının gücünü de dikkate alır. Bankanın likidite durumunu vadesi gelmiş borçlarını ödeme gücüne bakarak ve faiz oranları ile döviz kurlarındaki deđişiklikler karşısındaki duyarlılığını göz önüne alarak deđerlendirir (Fons, 1998: 6). Bu derecelendirme çerçevesinde ekonominin gücü, gelecekteki işleyişı, finansal sistemin yapısı, nispi kırılğanlığı, bankacılık konusundaki düzenlemelerin ve denetimin niteliđi gibi bankanın faaliyet çevresindeki diđer risk faktörleri de dikkate alınır (www.moodys.com). Temel finansal gücün belirlenebilmesi, derecelendirmeyi etkileyen olumsuz dış faktörlerin deđerlendirme harici bırakılmasını gerektirir. Burada dış faktörler bankanın yerleşik bulunduğu ülkeden kaynaklanabileceđi gibi, dış destek mekanizmalarının varlığı ile de bağlantılı olabilir. Nihayet finansal güç derecelendirmesi ile bankanın derecesi yüksek bir ülkede yerleşik olması durumunda derecesinin nasıl verilebileceđi sorusuna da cevap aranır.

## **2. Literatür İncelemesi**

Derecelendirme konusundaki çalışmalarda, farklı sektörlerde ve zaman periyotlarında, deđişik finansal oranlar ve istatistiksel teknikler kullanılarak modeller kurulmaya çalışılmıştır. Derecelendirme çalışmaları için kullanılan örnekler ağırlıklı olarak S&P's ve Moody's tarafından derecelendirilen şirket tahvillerinden seçilmiştir. Uygulanan istatistiksel teknikler başlangıçta regresyon ve diskriminant analizi, daha sonraları ise lojistik regresyon ve probit analizi olmuştur. Sadece Moody's tarafından 1995 tarihinden itibaren yapılmakta olan banka finansal güç derecelerinin tahminine ilişkin çalışmalar ise oldukça azdır.

Derecelendirmeye temel oluşturan ilk çalışma 1959'da Fisher tarafından yapılmıştır. Bu çalışmada derecelendirme dışında piyasa risk primi gibi bağımlı deđişken türleri araştırılmıştır. Fisher bu çalışmasında çoklu regresyon analizini kullanarak, tahvillerin piyasa risk primlerindeki deđişimi açıklamıştır.

İhraç edilen tahvilin derecesini tahmin etmek ve derece deđişmelerini önceden belirlemek amacıyla yapılan çok deđişkenli çalışmalar Horriğan (1966) ile başlamaktadır. Bu çalışmada 1954-69 yıllarında derecesi deđiştirilmemiş 352 firmadan (201'i Moody's, 151'i de S&P's tarafından derecelendirilmiştir) oluşan örnek modelin elde edilmesi için, 1961-64 yıllarında ihraç edilen ya da derecesi deđiştirilen 215 firmadan oluşan ikinci örnek ise modelin geçerliliđinin testi için kullanılmıştır. Çalışmada regresyon analizi uygulanmıştır. Likidite, karlılık, işletme büyüklüğü ve tahvilin yasal statüsünü yansıtan kukla deđişken olmak üzere toplam 18 açıklayıcı deđişken kullanılmıştır. Bağımlı deđişken olarak da, dokuz derece kategorisi için 1'den 9'a kadar tam sayılar alınmıştır. Derece farklarını yansıtan en iyi model olarak seçilen bu model, geçerlilik

testinde Moody's'in derecelerinin %58'ni, S&P's'un derecelerinin ise %52'sini doğru olarak tahmin etmiştir.

Bu konudaki diğer çalışma *West* (1970) tarafından gerçekleştirilmiştir. Çalışmada istatistik yöntem olarak regresyon analizi seçilmiştir. Fisher'in piyasa risk primi modelinde yer alan dört bağımsız değişken (firma karlarının değişkenliği, güvenilirlik, sermaye yapısı ve tahvillerin pazarlanabilirliği) kullanılmıştır. Bu çalışmada da *Horrigan*'da olduğu gibi bağımlı değişken olarak 1'den 9'a kadar tam sayılar kullanılmış ancak, sayıların logaritmaları alınmıştır. Model Moody's'in 1953 yılı derecelerinin %62'sini doğru olarak tahmin etmiştir.

*Pogue* ve *Slodofsky* (1969) tarafından geliştirilen modelde lineer regresyon analizi kullanılmıştır. Bu modelde 1961-1966 yıllarında Moody's'in Baa ve Aaa arası derecelendirdiği sanayi, kamu ve demiryolu tahvilleri %80 başarı ile sınıflandırılmıştır.

*Pinches* ve *Mingo*'nun çalışmasında (1973) ise çoklu diskriminant analizi yöntemi kullanılmıştır. 1 Ocak 1967-31 Aralık 1968 döneminde Moody's tarafından B veya B'nin üstünde derecelendirilen 132 firma diskriminant fonksiyonunun elde edilmesinde, 48 firma ise modelin geçerlilik testinde kullanılmıştır. Bağımsız değişkenler olarak; büyüklük, finansal kaldıraç, uzun vadeli sermaye yoğunluğu, yatırımın verimliliği, kısa vadeli sermaye yoğunluğu, kazançlardaki değişkenlik ve borç karşılamaadaki değişkenlik olmak üzere 7 grupta 35 finansal değişken tanımlanmıştır. Daha sonra bağımsız değişken boyutunu azaltmak amacıyla faktör analizi yapılmış ve modelde kullanılacak değişken sayısı altı olarak belirlenmiştir. Çalışmada diskriminant fonksiyonunun elde edildiği örneğe göre başarı oranı %69.70, geçerlilik testi amacıyla kullanılan örnek için ise doğru sınıflandırma yüzdesi %64.58 olarak belirlenmiştir. Tahvilin yasal statüsünü yansıtan değişken (subordination) açıklayıcı gücü en yüksek değişken olarak belirlenmiştir. *Pinches* ve *Mingo* iki yıl sonra (1975) tahvilin yasal statüsünü yansıtan değişkeni analiz dışında tutarak, diğer değişkenlere kuadratik diskriminant analizi uyguladıklarında başarı oranının %56'ya düştüğünü gözlemlemişlerdir.

*Belkaoui* de yapmış olduğu iki çalışmada (1980-1983) diskriminant analizini uygulamıştır. Çalışmada 1978 yılında S&P's'un B ve daha üst kategoride derecelendirdiği toplam 275 endüstri şirketi tahvilinden 160'ı diskriminant fonksiyonunun elde edilmesinde, 97'i ise fonksiyonların tahmin yeteneğinin testinde kullanılmıştır. Modele sekiz bağımsız değişken alınmıştır. Sonuç olarak diskriminant fonksiyonlarının elde edildiği örnekte yer alan

firmalar için dođru sınıflandırma oranı %62.8, geçerlilik testinde kullanılan firmalar için modelin başarıları %65.9 olarak açıklanmıştır.

Perry, Henderson ve Cronan (1984) ise altı farklı sanayi kolunda çeşitli örnekler üzerinde lineer diskriminant analizi uygulamıştır. Model ortalama %60 başarı göstermiştir.

Altman ve Katz, (1976) kamu elektrik kurumlarının tahvilleri üzerinde lineer ve kuadratik diskriminant analizlerini uygulayarak performanslarını karşılaştırmıştır. Kuadratik diskriminant analizinin derece tahmininde %77 ile daha yüksek bir başarı gösterdiği gözlenmiştir.

Martin ve Henderson (1983), 1979-1980 yıllarında Moody's tarafından B-Aaa olarak derecelendirilen 129 sanayi tahvili üzerinde rank diskriminant analizi uygulamış ve %56 dođru tahmin başarıları göstermiştir.

Lojistik regresyonun kullanıldığı çalışmalara örnek olarak Kaplan ve Urwitz'in çalışması (1979) verilebilir. Bu çalışmada lojistik regresyon modelinin elde edildiđi veri seti olarak Moody's'in 1971-1972 yılları arasında derecesini deđiştirmedeđi tahviller, geçerlilik testi için de söz konusu dönemde yeni derecelendirilen 53 tahvil alınmıştır. Dört açıklayıcı deđişken kullanılan modelde, dođru tahmin başarıları %69 olarak bulunmuştur.

Poon v.d. (1999), Moody's'in finansal güç derecelerini tahmin etmede lojistik regresyonu kullanmışlardır. Çalışmada 30'un üzerinde ülkeden 130 bankanın 1996 yılı finansal oranları alınarak, 1997 yılında Moody's'in verdiđi finansal güç dereceleri tahmin edilmeye çalışılmıştır. Veri setinin boyutunu indirgemek amacıyla öncelikle faktör analizi yapılmış; risk, takipteki alacak karşılıkları ve karlılığı temsil eden 3 faktör belirlenmiştir. Lojistik regresyon analizi kullanılarak 6 model geliştirilmiştir. Sırasıyla modellerin dođru tahmin performansı %52.3, %69.3, %21.1, %63.1, %69.0 ve %71.1 olarak bulunmuştur.

Lojistik regresyonun kullanıldığı bir başka çalışma ise, Ang ve Kiritkumar'ın çalışmasıdır (1978). Probit analizinin uygulandıđı çalışmalara örnek olarak ise Gentry, Newbold ve Whitford (1988) verilebilir.

Birden fazla istatistik tekniklerin karşılaştırıldığı bir çalışma da Ederington (1986) tarafından yapılmıştır. Bu çalışmada Moody's'in 1975-1979 yılları arasında B ve daha üst kategoride derecelendirdiđi tahviller kullanılarak beş farklı istatistiksel teknik uygulanmıştır. Modelin elde edilmesi için 246, geçerlilik testi için ise 100 tahvil alınmıştır. Dört bağımsız deđişkenin kullanıldığı çalışmada, probit tekniđi %78 ile en yüksek tahmin başarılarını göstermiştir.

İstatistiksel tekniklerin dışında tahvil derecelendirme probleminde yapay sinir ağının kullanıldığı çalışmalara ilk olarak Dutta, Shekhar (1988) ve Singleton, Surkan (1990) örnek verilebilir. Dutta ve Shekhar'ın çalışmasında 30 firma eğitim, 17 firma ise test amaçlı kullanılmıştır. Modele 10 açıklayıcı değişken alınmıştır ve yapay sinir ağı ile regresyon analizinin karşılaştırması yapılmıştır. Yapay sinir ağı %88.3, regresyon analizi ise %64.7 doğru tahmin başarısı göstermiştir. Singleton ve Surkan ise 126 tahvil ve yedi finansal oran kullanmışlar ve yapay sinir ağının başarısını %80, lineer diskriminant analizini ise %35 olarak açıklamışlardır.

Kim v.d. (1993) çalışmalarında, tahvil derecelendirmesinde yapay sinir ağları, lineer regresyon, diskriminant analizi, lojistik regresyon analizi ve kural tabanlı sistem tekniklerinin doğru sınıflandırma performanslarını karşılaştırmış ve yapay sinir ağlarının diğer tekniklere nazaran daha yüksek başarı gösterdiğini belirlemiştir. Çalışmada kullanılan veri seti S&P's Compustat'ın finansal verilerinden hazırlanmış ve bağımlı değişken 6 derecelendirme kategorisinden oluşmuştur.

Maher ve Sen (1997), Moody's Annual Bond Record ve S&P's Compustat'ın verilerine kullanarak hazırladıkları veri setiyle yapay sinir ağları ve lojistik regresyonun tahvil derecelendirme tahmin performanslarını karşılaştırmışlardır. Yapay sinir ağları %70, lojistik regresyon analizi ise %61.66 başarı göstermiştir. Yine Chavesuk v.d. (1999) tarafından yapılan benzer bir çalışmada geri yayımlı sinir ağları, radyal temelli fonksiyon, öğrenme vektör niceliklendirmesi ve lojistik regresyon analizinin sınıflandırma performansları karşılaştırılmıştır. Geri yayımlı sinir ağları ve lojistik regresyon analizinin sırasıyla %51.9 ve %53.3 başarı oranlarıyla diğerlerine nazaran daha yüksek performans gösterdiği sonucuna ulaşılmıştır.

Birden fazla yapay sinir ağı tekniği ve istatistiksel tekniklerin kullanıldığı bir çalışma da West tarafından yapılmıştır (2000). Bu çalışmada beş yapay sinir ağı tekniği (çok katmanlı algılayıcı, uzman sistemler, radyal temelli fonksiyon, öğrenme vektör niceliklendirmesi, bulanık adaptif rezonans (fuzzy ART) ile lineer diskriminant analizi, lojistik regresyon analizi, k en yakın komşuluk (k nearest neighbor), merkezi yoğunluk tahmini (kernel density estimation) ve karar ağaçları tekniklerini kullanarak kredi skorlama modeli geliştirilmiştir. Lojistik regresyonun en yüksek performansı gösteren teknik olduğu sonucuna varılmıştır.

Huang v.d. (2004) çalışmalarında yapay sinir ağı sistemlerinden geri yayımlı sinir ağları ve destek vektör makineleri teknikleri kullanarak kredi derecelendirme tahmini yapmışlardır. Çalışmada Tayvan'daki finansal

kuruluşların ve ABD'deki ticari bankaların verilerinden oluşan iki veri seti hazırlamışlar ve destek vektör makinelerinin performansının geri yayımlı sinir ağlarının performansından daha yüksek olduğu sonucuna ulaşmışlardır.

Derecelendirme konusunda yapay sinir ağının kullanıldığı diğer çalışmalara örnek olarak, Kim (1992), Baetge (1994), Moody ve Utans (1995), Baetge ve Jerschensky (1996), Burger ve Schellberg (1994), Burger ve Buchhart (1998) ve Tan v.d. (2002) verilebilir.

### **3. Model Oluşturma**

Bu çalışmada bankaların finansal güç derecelerinin tahminine yönelik bir model geliştirilmiştir. Çalışmanın metodolojisi, modelde yer alan bağımlı ve bağımsız değişkenlerin seçilmesi, veri setinin oluşturulması, kullanılacak tekniklerin seçimi ve bu tekniklerin doğru sınıflandırma başarısının değerlendirilmesinden oluşmaktadır.

#### **3.1. Değişkenlerin Seçilmesi**

Bir bankanın yapısal gücü genellikle CAMELS analizi çerçevesinde bankanın finansal durum ve performansına ilişkin altı farklı göstereyi içeren bir değerlendirmeyle ölçülür (Crystal, Dages, Goldberg, 2001: 6-8). Geliştirilen modelde bağımsız değişkenler, sermaye yeterliliği, aktif kalitesi, yönetim kalitesi, karlılık, likidite ve piyasa riskine duyarlılık (CAMELS) başlıklarında toplanan 20 finansal orandan oluşmuştur. Aşağıda bağımsız değişkenler kodlarıyla birlikte verilmektedir.

1. Sermaye Yeterliliği: Özkaynaklar / Toplam Aktifler (SY1), Özkaynaklar / Toplam Krediler (SY2), Özkaynaklar + Toplam Kar / Toplam Aktifler + Gayri Nakdi Krediler (SY3);

2. Aktif Kalitesi: Duran Aktifler / Toplam Aktifler (AK1), Toplam Krediler / Toplam Aktifler (AK2), Takipteki Krediler / Toplam Krediler (AK3), Takipteki Alacak Karşılıkları / Toplam Krediler (AK4), Takipteki Alacak Karşılıkları / Takipteki Krediler (AK5);

3. Yönetim Kalitesi: Faaliyet Giderleri / Toplam Aktifler (YK1);

4. Karlılık: Net Dönem Karı / Ortalama Toplam Aktifler (K1), Net Dönem Karı / Ortalama Özkaynaklar (K2), Vergi Öncesi Kar / Ortalama Toplam Aktifler (K3), Faiz Gelirleri / Toplam Gelirler (K4), Faiz Dışı Giderler / Toplam Gelirler (K5);

5. Likidite: Likit Aktifler / Toplam Aktifler (L1), Krediler / Toplam Mevduat (L2);

6. Piyasa Riskine Duyarlılık: Menkul Kıymet Cüzdanı / Toplam Aktifler (PRD1), YP Aktifler / YP Pasifler (PRD2), Net Faiz Geliri / Ortalama Toplam Aktifler (PRD3), Döviz Pozisyonu / Özkaynaklar (PRD4).

Bağımlı değişken olarak da, Moody's şirketinin finansal güç derecelendirme sistemiği alınmıştır. **A** (çok güçlü- very strong), **B** (güçlü-strong), **C** (iyi-good), **D** (yeterli- adequate), ve **E** (çok zayıf-very weak) derecelerinden oluşan bu sınıflandırmada Türk bankalarının D ve E derecelerini aldığı tespit edilmiştir. Bu nedenle modeldeki bağımlı değişken D ve E olmak üzere ikili grup olarak belirlenmiştir. Geliştirilen model bankaların sadece D ve E derecelerini almaları durumunda geçerlidir.

### **3.2. Veri Setinin Oluşturulması**

Veri setinin oluşturulmasında Türkiye Bankalar Birliği tarafından yıllık olarak yayımlanan bankalara ait bilanço, bilanço dışı yükümlülükler ve gelir-gider kalemleri kullanılmıştır.

Moody's'den 2001-2005 yılları arasında finansal güç derecesi alıp, modele dahil edilen 18 bankanın adları aşağıda verilmiştir: Ziraat Bankası, Vakıflar Bankası, Akbank, Anadolubank, Denizbank, Finans Bank, HSBC Bank, İktisat Bankası, Koçbank, Oyak Bank, Pamukbank, Tefkenbank, Toprakbank, Fortis (Dış Ticaret Bankası), Türk Ekonomi Bankası, Garanti Bankası, İş Bankası, Yapı ve Kredi Bankası.

Her yıl finansal güç derecesi alan banka sayısında değişiklik gözlenmiştir. Bu nedenle veri setine 2001 yılında 4, 2002 yılında 12, 2003 yılında 12, 2004 yılında 11 ve 2005 yılında 15 bankanın finansal güç dereceleri alınmıştır. Böylece söz konusu 18 bankanın verilerinden oluşan 54 gözlem birimli bir veri seti hazırlanmıştır. Veri setinden tesadüfi olarak seçilen ve %65'lik kısmını oluşturan 35 gözlem birimi modelin geliştirilmesinde, geri kalan %35'lik kısmını temsil eden 19 gözlem birimi de modelin geçerliliğinin testinde kullanılmıştır.

### **3.3. Teknik Seçimi**

Modelde iki farklı sınıflandırma sisteminden dört değişik analitik teknik seçilmiştir: Yapay sinir ağı sisteminden çok katmanlı algılayıcı ve çok değişkenli istatistiksel analiz tekniklerinden diskriminant analizi, kümeleme analizi ve lojistik regresyon analizi. Ayrıca modelde bağımsız değişkenlerin boyutunu indirgemek amacıyla faktör analizi de uygulanmıştır. Geçmiş finansal güç derecelendirme verileri kullanılarak bu tekniklerin sınıflandırma ve tahmin performansları karşılaştırılmıştır. Yapay sinir ağı MATLAB yazılımının Neural

Network araç kutuları, çok deđişkenli istatistiksel analiz teknikleri ise MINITAB ve SPSS paket programları kullanılarak uygulanmıştır.

#### 4. Bankaların Finansal Güç Derecelerinin Yapay Sinir Ağları ve Çok Deđişkenli İstatistiksel Analiz Teknikleri ile Tahmini

Çalışmada geliştirilen temel hipotez yapay sinir ağlarının grupları sınıflandırma performansının istatistiksel tekniklerin grupları sınıflandırma performansına göre farklılık gösterip göstermediğidir.

$H_0: P_{(YSA)} = P_{(IT)}$ , yapay sinir ağının grupları doğru sınıflandırma performansı ile istatistiksel tekniklerin grupları doğru sınıflandırma performansı farksızdır.

$H_1: P_{(YSA)} \neq P_{(IT)}$ , yapay sinir ağının grupları doğru sınıflandırma performansı ile istatistiksel tekniklerin grupları doğru sınıflandırma performansı farklıdır.

Hipotezin test edilmesinde 2-oranlı z testi istatistiđi kullanılmıştır.

Çalışmanın ilk aşamasında, orijinal veri setindeki deđişkenler arasında korelasyonun olup olmadığını tespit etmek amacıyla Pearson korelasyon matrisi hesaplanmıştır ve deđişkenler arasında çoklu doğrusal bağlantı (multicollinearity) olduğu belirlenmiştir. Bu aşamada aralarında yüksek korelasyon bulunan ve modelin açıklayıcılık gücüne katkı sağlamayacak çok sayıda finansal oran yerine, bu oranlardaki toplam deđişimin kabul edilebilir bir kısmını açıklayan birbirinden bağımsız faktörler elde ederek veri boyutunu indirgemek ve bu şekilde daha objektif bir deđerlendirme yapabilmek amacıyla faktör analizi uygulanmıştır.

#### 4.1. Faktör Analizi Uygulaması ve Sonuçların Deđerlendirilmesi

2001-2005 yılı verilerine faktör analizinin uygunluđunu test etmek amacıyla Kaiser-Meyer-Olkin (KMO) ve Bartlett küresellik testleri (Bartlett's Test of Sphericity) yapılmıştır. Sonuçlar aşağıda verilmektedir:

**Tablo 1: KMO ve Bartlett Küresellik Testleri Sonuçları**

KMO Testi		.701
Bartlett Küresellik Testi	Ki-kare	1529.859
	sd	190
	p	.000

Yukarıdaki her iki testten de anlaşılacağı üzere  $\alpha=0.01$  anlamlılık düzeyinde  $p \leq \alpha$  olduğundan  $H_0$  hipotezi ( $H_0: R=I$ ) reddedilir,  $H_1$  hipotezi ( $H_1: R \neq I$ ) kabul edilir. Korelasyon matrisi (R) birim matrise (I) eşit olmadığından, deđişkenler arasında bir korelasyon vardır ve %70.1'lik KMO deđeri bunu



desteklemektedir. Faktör analizinin değişkenlere uygulanabilirliği söz konusudur.

Faktör analizinde temel bileşenler yöntemi kullanılmıştır. Temel bileşenler yönteminde 2001-2005 yılları için hesaplanan 20 adet finansal oran değişken olarak alınırken, bankalar gözlem birimi olarak yer almıştır. Analizinde ilk etapta orijinal veriler standardize edilmiş, daha sonra standartlaştırılmış veriler üzerinden korelasyon matrisi kullanılarak temel bileşenler bulunmuştur.

Faktör sayısının belirlenmesinde özdeğerleri 1'den büyük olan ve toplam varyansın en az %67 ve daha fazlasını (%95'lere kadar) açıklayan bileşenlerin seçilmesi kriterleri ile yamaç eğimi grafiği (scree plot) yöntemi birlikte değerlendirilmiştir. Tablo 2'den de görüldüğü üzere toplam varyansın %79.73'ünü açıklayan 5 faktör elde edilmiştir.

**Tablo 2:** Faktörlerin Özdeğerleri ve Varyansı Açıklama Yüzdeleri

Faktör	Özdeğer	Varyansı Açıklama (%)	Toplam Varyansı Açıklama (%)
1	6.492	32.462	32.462
2	3.110	15.551	48.013
3	2.737	13.686	61.700
4	1.969	9.845	71.545
5	1.638	8.189	79.734
6	.963	4.814	84.548
7	.865	4.326	88.874
8	.755	3.773	92.647
9	.498	2.489	95.135
10	.328	1.639	96.774
11	.238	1.190	97.964
12	.146	.729	98.694
13	.103	.514	99.207
14	7.085E-02	.354	99.561
15	3.461E-02	.173	99.734
16	2.092E-02	.105	99.839
17	1.800E-02	9.000E-02	99.929
18	9.856E-03	4.928E-02	99.978
19	2.870E-03	1.435E-02	99.993
20	1.467E-03	7.334E-03	100.000

Kavramsal anlamlılığın sağlanması amacıyla eksen rotasyonu yöntemlerinden varimax yöntemi kullanılmış ve faktörlerin kavramsal

anlamlılıđında artma gözlenmiştir. Bu nedenle yorumlarda varimax yöntemi sonuçları kullanılmıştır.

**Tablo 3:** Döndürölmüş Faktör Matrisi

	1	2	3	4	5
SY1	.573	.244	.270	<b>.653</b>	.203
SY2	<b>.841</b>	4.484E-02	6.444E-02	.482	.141
SY3	.536	-1.039E-02	<b>.605</b>	.484	.201
AK1	-8.196E-02	-.118	<b>-.658</b>	.156	-.304
AK2	.171	<b>.949</b>	3.947E-02	6.501E-02	6.516E-03
AK3	<b>-.966</b>	-.196	3.397E-02	1.523E-02	1.857E-02
AK4	<b>-.940</b>	-.280	3.204E-02	-4.576E-02	-3.941E-02
AK5	-.117	-.123	.519	8.052E-02	-.148
YK1	-9.333E-02	.333	.250	6.036E-02	-.426
K1	.200	.101	<b>.891</b>	.117	-4.729E-02
K2	.136	5.090E-02	<b>.759</b>	.190	-.457
K3	<b>.889</b>	.181	.394	1.668E-02	-7.781E-02
K4	1.251E-02	3.013E-02	-.283	.414	<b>.765</b>
K5	1.246E-02	-.147	-.116	<b>-.886</b>	.166
L1	-.329	-.388	.266	-.308	-.156
L3	.150	<b>.925</b>	.162	8.617E-02	4.870E-02
PRD1	-.279	<b>-.756</b>	.123	.174	-8.629E-02
PRD2	.150	-.217	5.520E-02	<b>.870</b>	.213
PRD3	.432	7.037E-02	1.234E-02	.174	<b>.823</b>
PRD4	.290	-.254	-.160	.148	<b>-.759</b>

Başlangıç istatistikleri sonucunda modele alınan 5 faktörden ilki, 6.492'lik özdeđer ile toplam varyansın %32'sini açıklamaktadır. En fazla açıklama gücüne sahip olan birinci faktörde yoğunlaşan deđişkenlerin aktif kalitesine ilişkin oranları (AK3, AK4) kapsadığı gözlenmektedir. Aktif kalitesi oranlarının ardından sermaye yeterliliđi oranı SY2 ve karlılık oranı K3 gelmektedir. Kavramsal anlamlılık açısından bakıldığında bu faktör "aktif kalitesi" bileşeni olarak adlandırılabilir.

Toplam deđişimin yaklaşık %16'sını açıklayan ikinci faktörde ise, aktif kalitesi oranı AK2, likidite oranı L3 ve piyasa riskine duyarlılık oranı PRD1 yer almaktadır. Bu faktörün karma bir yapıya sahip olduđu görölmektedir.

Üçüncü faktörde, karlılıkla ilgili oranlardan K1 ve K2 oranları ile sermaye yeterliliđi oranı SY3 ve aktif kalitesi oranı AK1'in yer aldığı

gözlendirmektedir. Söz konusu faktörün toplam değişimi açıklama yüzdesi 13.68'dir. Bu faktörü "karlılık" bileşeni olarak adlandırabilmek mümkündür.

Toplam değişimin %9.84'ünü açıklayan dördüncü faktörde, sermaye yeterliliği oranı SY1, karlılık oranı K5 ve piyasa riskine duyarlılık oranı PRD2 yer almaktadır. Kavramsal anlamlılık açısından bakıldığında bu faktör "karma faktör" özelliği taşımaktadır.

Beşinci faktörde ise, karlılık oranı K4 ile piyasa riskine duyarlılık oranları PRD3 ve PRD4 bulunmaktadır. Toplam değişimin %8.18'ini açıklayan bu faktör, kavramsal anlamlılık açısından "piyasa riskine duyarlılık" bileşeni olarak isimlendirilebilir.

Seçilen faktörlerin açıklama yüzdeleri yeterince yüksek olduğundan, aşağıda kullanılacak olan istatistiksel tekniklerde faktör analizi ile boyutu indirgenmiş veri seti kullanılacaktır.

#### **4.2. Diskriminant Analizi Uygulaması ve Sonuçların Değerlendirilmesi**

Çalışmada grup farklılıklarını karakterize etmek ve grup üyelikleri bilinmeyen birimleri sınıflandırmak amacıyla diskriminant analizi uygulanmıştır. Diskriminant analizinde öncelikle grup kovaryans matrislerinin eşitliği varsayımının veri seti üzerinde geçerliliğini test etmek amacıyla Box's M testi yapılmıştır. Box's M testi sonucuna göre grupların kovaryans matrisleri homojen değildir ( $p=0.000$ ). Bu nedenle verilere grupların kovaryans matrislerinin homojen olduğu varsayımını kullanmayan karesel (quadratic) diskriminant analizi uygulanması uygundur.

**Tablo 4:** Box's M Testi Sonucu

Box's M		152.347
F	Approx.	7.199
	df1	15
	df2	659.456
	Sig.	.000

Diskriminant analizinde öncelikle modeldeki veri seti iki gruba ayrılmıştır. Birinci grup diskriminant fonksiyonun elde edilmesinde veya modelin geliştirilmesinde, ikinci grup ise modelin ya da elde edilen fonksiyonun başarısının testinde kullanılmıştır. Moody's tarafından derecelendirilen 18 bankanın verilerinden oluşan 54 gözlem birimli bir veri setinden tesadüfi olarak seçilen 35 gözlem birimi modelin geliştirilmesinde, 19 gözlem birimi ise modelin geçerliliğinin testinde kullanılmıştır.

Diskriminant analizinde gruplara ayırma yeteneđini yükselten ve Wilks' Lambda'yı minimize eden bir kanonik diskriminant fonksiyon elde edilmiştir. Diskriminant fonksiyonlarının ayırıcılık özelliđini gösteren özdeđer, fonksiyon için 0.774'dür. Fonksiyon toplam varyansın %100'ünü açıklamaktadır.

**Tablo 5:** Diskriminant Analizinde Özdeđerler

Fonksiyon	Özdeđer	Varyans %	Kümülatif %	Kanonik Korelasyon
1	.774	100.0	100.0	.660

Bulunan diskriminant fonksiyonunun istatistiksel önemini ya da bir başka ifadeyle birimleri gruplara ayırma özelliđinin iyi olup olmadığını gösteren Wilks' Lambda deđeri 0.564'dür. Bu deđer ne kadar küçükse, fonksiyonların ayırt edici gücü o kadar artmaktadır. Fonksiyonun da ayırma gücü önemli düzeyde yüksektir (p=0.004).

**Tablo 6:** Diskriminant Analizinde Wilks' Lambda

Fonksiyonların Testi	Wilks' Lambda	Chi-square	Df	Sig.
1	.564	17.477	5	.004

Kanonik diskriminant fonksiyonu aşağıda verilmektedir:

$$Y1=0.002+0.361*F1+1.071*F2-0.113*F3-0.056*F4+0.256*F5$$

Tablo 7 incelendiđinde, diskriminant analizi sonucunda fonksiyonun elde edildiđi verisinde E grubunda yer alan 8 gözlem biriminin 7'si E grubuna atanmış, bir tanesi hatalı sınıflandırılmıştır. D grubunda yer alan 27 gözlem biriminin 24'ü D grubunda, 3'ü E grubunda yer almıştır. Fonksiyonun geçerliliđinin test edildiđi veri setindeki 19 gözlem biriminin 15'i D grubuna, 4'ü de E grubuna atanmıştır.

**Tablo 7:** Diskriminant Analizinin Sınıflandırma Sonuçları

			Tahmin edilen grup üyeliđi		Toplam
		GRUP	.00	1.00	
Orijinal	Gözlem Sayısı	.00	7	1	8
		1.00	3	24	27
		Gruplandırılmayan Gözlemler	4	15	19
	%	.00	87.5	12.5	100.0
		1.00	11.1	88.9	100.0
		Gruplandırılmayan Gözlemler	21.1	78.9	100.0

Diskriminant fonksiyonunun elde edildiği veri setinde orijinal grupların %88.6'ı doğru tahmin edilmiş, fonksiyonun geçerliliğinin test edildiği veri setinde ise başarı oranı %73.6 olarak belirlenmiştir. Diskriminant analizi, eğitim setindeki 35 adet gözlem biriminin 31'inin finansal güç derecesini doğru tahmin etmiştir. Test setindeki toplam 19 gözlem biriminin ise 14 tanesini doğru sınıflandırmıştır.

#### 4.3. Kümeleme Analizi Uygulaması ve Sonuçların Değerlendirilmesi

Kümeleme analizinde hiyerarşik olmayan k-ortalamlar tekniği kullanılmıştır. Bu teknikte birimler, kümeler içi kareler toplamı en küçük olacak biçimde k kümeye bölünmektedir.  $X_1, X_2, \dots, X_n$  değerlerinin her biri p değişkenli gözlem vektörleri çok boyutlu X uzayında birer nokta olarak düşünüldüğünde ve aynı uzayda  $a_{1n}, a_{2n}, \dots, a_{kn}$  her grup birey için küme merkezleri olarak seçildiğinde;  $W_n = 1/n[\sum |X_i - a_{jn}|]$  kuralı gereğince birimler en yakın kümeye atanmaktadır. Bu teknikte gruplayıcı değişken yoktur ve analiz 2 grup üzerinden yapılmıştır.

Faktör analizinde elde edilen 5 adet faktöre göre analiz gerçekleştirilmiştir. Kümeleme analizinde hangi değişkenlerin işleme alınıp, hangilerinin analiz dışı bırakıldığını saptamak için varyans analizi yapılmıştır. Sonuçlar Tablo 8'de yer almaktadır.

**Tablo 8:** Anova Tablosu

	Küme		Hata		F	p
	Kareler ortalaması	sd	Kareler ortalaması	sd		
C1	16.632	1	.699	52	23.781	.000
C2	1.103	1	.998	52	1.105	.298
C3	2.830	1	.965	52	2.933	.093
C4	.863	1	1.003	52	.861	.358
C5	23.200	1	.573	52	40.484	.000

Tablo 8 incelendiğinde C1 ve C5 değişkenlerinin p değerleri  $\alpha=.01$ 'den, C3 değişkeninin p değeri de  $\alpha=.10$ 'dan küçük olduğu için; bu değişkenlere göre kümeler arasında anlamlı bir farklılık vardır. Kümeleme analizinde C1, C3 ve C5 değişkenleri işleme alınmıştır.

Analiz sonucunda oluşan iki kümeden birincisi 51, ikincisi ise 3 elemanlıdır. Kümeleme analizi, eğitim setinde grupların %74.2'sini doğru tahmin etmiştir. Test setinde ise başarı oranı %73.6 olarak belirlenmiştir. Kümeleme analizi, eğitim setindeki 35 adet gözlem biriminin 26'sının finansal güç derecesini doğru sınıflandırmıştır. Test setindeki toplam 19 gözlem biriminin ise 14 tanesini doğru tahmin etmiştir.

#### 4.4. Lojistik Regresyon Analizi Uygulaması ve Sonuçların Deđerlendirilmesi

Çalışmada grup farklılıklarını karakterize etmek, grup üyelikleri bilinmeyen birimleri sınıflandırmak ve grup üyeliklerine ilişkin olasılıkları belirlemek amacıyla lojistik regresyon analizi kullanılmıştır. Bađımlı deđişken iki kategoriden oluştuđu, faktörler kategorik yapıda ve ortak deđişkenler sürekli deđişken tipinde olduđu için binary lojistik regresyon yöntemi uygulanmıştır.

**Tablo 9:** Lojistik Regresyon Tablosu

Tahmin edici	Katsayı	SE Katsayı	Z	p	Odds Oranları	95% CI	
						Düşük	Yüksek
Sabit	1.589	1.244	1.28	0.202			
C1	4.354	5.269	0.83	0.409	77.82	0.00	2.38E+06
C2	3.171	1.394	2.27	0.023	23.82	1.55	366.32
C3	0.809	1.269	0.64	0.524	2.24	0.19	26.99
C4	-0.676	2.252	-0.30	0.764	0.51	0.01	41.97
C5	1.612	1.876	0.86	0.390	5.01	0.13	198.08

Lojistik regresyon tablosu incelendiđinde C2 deđişkeni  $\alpha=0.05$  anlamlılık düzeyinde önemli risk faktörleri olarak belirlenmiştir. Aşadıdaki sonuçlar kurulan lojistik modelin anlamlı olduğunu göstermektedir:

$$\text{Log-Likelihood} = -8.644$$

$$G = 20.341; \text{SD} = 5; p = 0.001$$

Lojistik regresyon tablosundaki katsayılar kullanılarak gözlem birimlerinin gruplara atanma olasılıkları şu şekilde hesaplanır:

$$P(Y) = [e^{Z_i} / (1 + e^{Z_i})] = [1 / (1 + e^{-Z_i})] \quad (1)$$

$$Z_i = 1.589 + 4.354 * C1 + 3.171 * C2 + 0.809 * C3 - 0.676 * C4 + 1.612 * C5$$

Eđer  $P(Y) < 0.50$  ise  $Y=0$  alınır.  $P(Y) \geq 0.50$  ise  $Y=1$  alınır.


Lojistik regresyon analizi modelin elde edildiđi veri setinde orijinal grupların %91.4'ünü dođru tahmin etmiştir. Modelin geçerliliđinin test edildiđi veri setinde ise başarı oranı %68.4 olarak belirlenmiştir. Lojistik regresyon analizi, eđitim setindeki 35 adet gözlem biriminin 32'sinin finansal güç derecesini dođru tahmin etmiştir. Test setindeki toplam 19 gözlem biriminin ise 13 tanesini dođru sınıflandırmıştır.

#### **4.5. Yapay Sinir Ağı Uygulaması ve Sonuçların Değerlendirilmesi**

Yapay sinir ağları, beynin çalışma sisteminin modellenmesi sonucu oluşturulmuş hesaplama sistemleridir. Bu sistemler, örnekler üzerinden öğrenerek yeni durumlara uyum sağlama yeteneğine sahiptir (Chu, 1997). Bu hesaplama sistemleri, beyindeki gerçek sinir hücrelerinde olduğu gibi, çok sayıda yapay sinir hücresinin birbirlerine değişik şekillerde bağlanması ile oluşturulur. Hücreler arasındaki bağlantıların biçimine bağlı olarak, değişik yapay sinir ağı modelleri geliştirilmiştir (Rumelhart v.d. 1989).

Bu çalışmada, bankaların finansal güç derecelerinin tahmininde, çok katmanlı algılayıcı (multilayer perceptron) ileri beslemeli (feed-forward) yapay sinir ağı modeli kullanılmıştır. Bu model, geri yayılım ağı (back propagation network) olarak da adlandırılır. Geri yayılım ağı bir giriş katmanı, bir çıkış katmanı ve bir veya daha fazla sayıda birbirine paralel gizli katmanlardan meydana gelir. Bu yapı içerisindeki herhangi bir yapay sinir hücresinin çıktı değerinin aralığının belirlenmesinde kullanılan fonksiyonlar, aktivasyon fonksiyonları olarak adlandırılır. Aktivasyon fonksiyonları, yapay sinir ağının performansı üzerinde etkili olabileceği gibi, sistemin çıktılarına bağlı olarak değiştirilebilmektedir.

Bu çalışmada kullanılan geri yayılım ağının giriş katmanında, her biri bir finansal oranı temsil etmek üzere, 20 adet yapay sinir ağı hücresi bulunmaktadır. Yapay sinir ağının çıkış katmanında ise sadece 1 adet hücre bulunmaktadır. Bu hücre, sisteme girdi olarak verilen bir bankanın finansal güç derecesinin D veya E olduğunu tahmin etmede kullanılmaktadır. Yapay sinir ağının çıkış katmanında kullanılan aktivasyon fonksiyonu, 0 ile 1 arasında değerler üreten lojistik sigmoid fonksiyonudur. Söz konusu fonksiyon, hücelere verilen girdiler hangi aralıkta olursa olsun, 0 ile 1 arasında değerler üretmektedir. Çıkış hücresinin çıktı değerine bağlı olarak bankaların finansal güç derecesinin D veya E olduğu belirlenmektedir. Bu doğrultuda şu yöntemle sınıflandırma kararı verilmiştir. Eğer çıkış değeri 0.5 değerinden küçük ise bankanın finansal güç değeri E, eğer çıkış değeri 0.5 veya büyük bir değer ise D olarak belirlenmiştir. Aşağıda Şekil 1’de, çalışmada kullanılan geri yayılım ağının yapısı görülmektedir.



Şekil 1: Geri Yayınım Ağının Yapısı

Kullanılan yapay sinir ağındaki ara katman sayısının ve bu ara katmanlardaki hücre sayısının belirlenmesinde izlenen yöntem ise şöyledir: İlk yapay sinir ağı boş bir ara katman ile oluşturulmuş ardından, yapay sinir ağı performansında herhangi bir iyileşme olmayıncaya kadar bir adet yeni hücre eklenmiştir. Bu işlem, yeni hücre ve ara katman eklenmesinin ağın performansında herhangi bir iyileşmeye etkisi kalmayıncaya kadar devam edilmiştir. Bu yöntem ile yapılan denemeler sonucunda, 4 ara katmanlı ve her bir ara katmanda 30 hücreli yapay sinir ağı yapısı benimsenmiştir. Tüm ara katmanlarda lojistik sigmoid aktivasyon fonksiyonu kullanılmıştır. Oluşturulan yapay sinir ağı eğitim veri seti ile ağın performansında iyileşme sağlanamayana kadar (maks. 1000 iterasyon) eğitilmiş, ardından ağın test veri setindeki veriler ile simülasyonu yapılmıştır. Yapay sinir ağına eğitiminde öğrenme oranı 0,01 ve momentum sabiti 0,90 olarak seçilmiştir.

Yukarıda verilen bilgiler doğrultusunda, eğitim ve test işlemleri tamamlandığında yapay sinir ağına eğitim performansının %100, test performansının ise %84.2 olduğu görülmüştür. Yapay sinir ağı, eğitim setindeki 35 gözlem biriminin tamamının finansal güç derecesini doğru tahmin etmiştir. Test setindeki toplam 19 gözlem biriminin ise 16 adedinin finansal güç derecesini doğru tahmin etmiştir.

##### 5. Tekniklerin Performanslarının Karşılaştırması

Bu çalışmada finansal güç derecelerinin tahmininde yapay sinir ağına performansı, çok değişkenli istatistiksel analiz tekniklerinin performansı ile karşılaştırılmıştır. Yapay sinir ağı ve istatistiksel tekniklerin modelin elde edildiği ve geçerliliğinin test edildiği veri setlerindeki performans sonuçları Tablo 10'da yer almaktadır.



**Tablo 10:** Modelde Kullanılan Tekniklerin Modelin Elde Edildiği ve Geçerliliğinin Test Edildiği Veri Setlerindeki Performans Sonuçları

Veri Seti/Teknikler	Diskriminant	Lojistik Regresyon	Kümeleme	Multilayer Perceptron
Modelin Elde Edildiği Veri Seti	%88.6	%91.4	%74.2	%100
Modelin Geçerliliğinin Test Edildiği Veri Seti	%73.6	%68.4	%73.6	%84.2

Tablo 10 incelendiğinde, modelin elde edildiği veri setinde en yüksek başarıya (%100) yapay sinir ağının sahip olduğu görülmektedir. Bu performansı sırasıyla lojistik regresyon (% 91.4), diskriminant analizi (%88.6) ve kümeleme analizi (% 74.2) izlemektedir. Test veri setinde de en yüksek başarıyı (%84.2) yine yapay sinir ağı göstermiştir. Bunu sırasıyla diskriminant (%73.6), kümeleme analizi (%73.6) ve lojistik regresyon analizinin (%68.4) izlediği görülmektedir.

**Tablo 11:** Modelde Kullanılan İstatistiksel Teknikler İle Yapay Sinir Ağının Performanslarının Karşılaştırıldığı 2-Oranlı Z Testi Sonuçları

Veri Seti /Teknikler	Diskriminant	Lojistik Regresyon	Kümeleme
Modelin Tahmin Edildiği Veri Seti	p=0.034**	p=0.070***	p=0.001*
Modelin Geçerliliğinin Test Edildiği Veri Seti	p=0.422	p=0.244	p=0.422

\*  $\alpha=.01$  de anlamlı

\*\*  $\alpha=.05$  de anlamlı

\*\*\*  $\alpha=.10$  da anlamlı

Çalışmanın son aşamasında elde edilen bulgular ışığında  $H_0: P_{(YSA)} = P_{(IT)}$  ve  $H_1: P_{(YSA)} \neq P_{(IT)}$  hipotezi 2-oranlı z testi istatistiği kullanılarak test edilmiştir. Yapay sinir ağı ile diğer istatistiksel tekniklerin performanslarının karşılaştırıldığı 2-oranlı z testi sonuçları Tablo 11’de yer almaktadır. Bu tabloya göre yapay sinir ağı, modelin elde edildiği veri setinde  $\alpha=.01$  anlamlılık düzeyinde kümeleme,  $\alpha=.05$  anlamlılık düzeyinde diskriminant ve  $\alpha=.10$  anlamlılık düzeyinde de lojistik regresyon analizine göre yüksek bir sınıflandırma performansı göstermiştir. Modelin geçerliliğinin test edildiği veri setinde ise kullanılan tekniklerin tahmin performansları arasında anlamlı bir fark bulunamamıştır.

## **6. Sonu**

Finansal g derecelendirmesi ile hedeflenen, bir bankanın temel finansal gcnn dıř faktrlerin deęerlendirme harici bırakılması suretiyle lclmesidir. Yapılan deęerlendirme ile bankanın, koruyucu dıř faktrlerden tamamen arındırılmıř derecelendirmesi “nasıl olurdu?” sorusuna cevap aranır. Ayrıca bu deęerlendirmede bankanın finansal temeli, řube aęının gc, faaliyet alanlarındaki ve varlıklarındaki eřitlilik incelenir. Bankaya iliřkin temel analizde ise genel olarak; bankanın sermaye yeterlilięi, aktif kalitesi, kredi riski ynetiminin kalitesi, kredi portfynn ve ynetiminin kalitesi ile ynetimin izledięi strateji, karlılık, risk ynetimi, likidite, bankanın mlkiyet yapısı, finansal esneklik ve bankanın faaliyet gsterdięi yasal ereve zerinde durulur. Bu derecelendirme tr Moody’s řirketi tarafından yapılmaktadır.

Bu alıřmada bankaların finansal g derecelerinin tahmin etmek amacıyla bir model geliřtirilmiřtir. Modelde iki farklı sınıflandırma sisteminden drt deęiřik analitik teknik seilmiřtir. Bunlar; yapay sinir aęı sisteminden ok katmanlı algılayıcı ve ok deęiřkenli istatistiksel analiz tekniklerinden diskriminant analizi, kmeleme analizi ve lojistik regresyon analizi. Bankaların gemiř finansal g derecelendirme verileri kullanılarak bu tekniklerin sınıflandırma ve tahmin performansları karřılařtırılmıřtır. Ayrıca modelde baęımsız deęiřkenlerin boyutunu indirgemek amacıyla faktr analizi de uygulanmıřtır.

Sonu olarak, yapay sinir aęı, modelin elde edildięi veri setinde ok deęiřkenli istatistiksel analiz teknikleri ne gre yksek bir sınıflandırma performansı gstermiřtir. Modelin geerlilięinin test edildięi veri setinde ise kullanılan tekniklerin tahmin performansları arasında anlamlı bir fark bulunamamıřtır.

## **ABSTRACT**

### **A PERFORMANCE COMPARISON BETWEEN ARTIFICIAL NEURAL NETWORKS AND MULTIVARIATE STATISTICAL METHODS IN FORECASTING FINANCIAL STRENGTH RATING IN TURKISH BANKING SECTOR**

Financial strength rating indicates the fundamental financial strength of a bank. The aim of financial strength rating is to measure a bank’s fundamental financial strength excluding the external factors. External factors can stem from the working environment or can be linked with the outside protective support mechanisms. With the evaluation, the rating of a bank free from outside supportive factors is being sought. Also the financial fundamental, franchise

value, the variety of assets and working environment of a bank are being evaluated in this context.

In this study, a model has been developed in order to predict the financial strength rating of Turkish banks. The methodology of this study is as follows: Selecting variables to be used in the model, creating a data set, choosing the techniques to be used and the evaluation of classification success of the techniques. It is concluded that the artificial neural network system shows a better performance in terms of classification of financial strength rating in comparison to multivariate statistical methods in the raining set. On the other hand, there is no meaningful difference could be found in the validation set in which the prediction performances of the employed techniques are tested.

**Key Words:** Banks, Financial Strength Rating, Artificial Neural Networks, Multivariate Statistical Methods.

#### KAYNAKÇA

- ALTMAN, E. I., S. KATZ (1976), "An Analysis of Bond Ratings in the Electric Public Utility Industry", *Proceeding of the Conference on Topical Research in Accounting*, G. Sorter, M. Schiff (Ed.), Ross Institute, New York University.
- ANG, J. S., P. A. KIRITKUMAR (1978), "Bond Rating Methods: Comparison and Validation", *The Journal of Finance*.
- BAETGE, J. (1994), "Rating von Unternehmen anhand von Bilanzen", *Die Wirtschaftsprüfung*, Heft 1.
- BAETGE, J., A. JERSCHENSKY (1996), "Beurteilung der wirtschaftlichen Lage von Unternehmen mit Hilfe von modernen Verfahren der Jahresabschlussanalyse", *Der Betrieb*, Heft 32.
- BELKAOUI, A. (1980), "Industrial Bond Ratings, A New Look", *Journal of Financial Management*, Vol. 9, No.3.
- BELKAOUI, A. (1983), "Industrial Bonds and The Rating Process", *CT: Quorum Books*, Wesport.
- BURGER, A., B. SCHELLBERG (1994), "Rating von Unternehmen mit neuronalen Netzen", *Betriebs-Berater*, Heft 13.
- BURGER, A., A. BUCHHART (1998), "Rating und Risikokosten im Kreditgeschaef", *Die Bank*, Heft 7.
- CHAVEESUK, R., C. SRIVAREE-RATANA, A. E. SMITH (1999), "Alternative Neural Network Approaches to Corporate Bond Rating", *Journal of Engineering Valuation and Cost Analysis*, Vol. 2, No. 2.

- CHU, C.H. (1997), "An Improved Neural Network for Manufacturing Cell Formation", *Decision Support Systems*, Vol. 20.
- CRYSTAL, J. S. B., G. DAGES, L. S. GOLDBERG (2001), "Does Foreign Ownership Contribute to Sounder Banks in Emerging Markets? The Latin American Experience", *Federal Reserve Bank of New York*.
- DUTTA, S., S. SHEKHAR (1988), "Bond Rating: A Non Conservative Application of Neural Networks", *Proceedings of the IEEE International Conference on Neural Networks*, Vol. 2, San Diego.
- EDERINGTON, L. H. (1986), "Why Split Ratings Occur", *Financial Management*, Vol. 15.
- FISHER, F. (1959), "Determinants of Risk Premiums on Corporate Bond", *Journal of Political Economy*, June.
- FONS, J. S. (1998), "Improving Transparency in Asian Banking Systems", *Moody's Investors Service*.
- GENTRY, J., P. NEWBOLD, D. WHITFORD (1988), "Predicting Industrial Bond Ratings with a Probit Model and Funds Flow Components", *Financial Review*, Vol. 23, No. 3.
- HORRIGAN, J. O. (1966), "The Determination of Long-Term Credit Standing with Financial Ratios", *Empirical Research in Accounting: Selected Studies*, *Supplement to Journal of Accounting Research*, Vol. 4.
- HUANG, Z., H. CHEN, C.J. HSU, W.H. CHEN, S. W. (2004), "Credit Rating Analysis with Support Vector Machines and Neural Networks: A Market Comparative Study", *Decision Support Systems*, Vol. 37.
- KAPLAN, R., S. G. URWITZ (1979), "Statistical Models of Bond Ratings: A Methodological Inquiry", *Journal of Business*, Vol. 52, No. 2.
- KIM, J. W. (1992), *A Comparative Analysis of Rule-based, Neural Network and Statistical Classification Systems for The Bond Rating Problem*, PhD, Virginia Commonwealth University, Richmond.
- KIM, J. W., R. H. WEISTROFFER, R. T. REDMOND (1993), "Expert Systems for Bond Rating: A Comparative Analysis of Statistical, Rule-based and Neural Network Systems", *Expert Systems*, Vol. 10, No. 3.
- MAHER, J. J., T. K. SEN (1997), "Predicting Bond Ratings Using Neural Networks: A Comparison with Logistic Regression", *Intelligent Systems in Accounting, Finance and Management*, Vol. 6.

- MARTIN, L. J., G. V. HENDERSON (1983), “On Bond Ratings and Pension Obligations: A Note”, *Journal of Financial and Quantitative Analysis*, Vol. 18.
- MOODY, J., J. UTANS (1995), “Architecture Selection Strategies for Neural Networks Application to Corporate Bond Rating”, in: A. Refenes (Ed.), *Neural Networks in the Capital Markets*, Wiley, Chichester.
- PERRY, L. G., HENDERSON G. V. , T. P. CRONAN (1984), “Multivariate Analysis of Corporate Bond Ratings and Industry Classification”, *The Journal of Financial Research*, Vol. 7, No. 1.
- PINCHES, G. E., K. A. MINGO (1973), “A Multivariate Analysis of Industrial Bond Ratings”, *Journal of Finance*, Vol. 28, No. 1.
- PINCHES, G. E., K. A. MINGO (1975), “The Role of Subordination and Industrial Bond Ratings”, *Journal of Finance*, Vol. 30, No. 1.
- POGUE, T. F., R. M. SOLDOSKY (1969), “What’s in A Bond Rating”, *Journal of Financial and Quantitative Analysis*, Vol. 4, No. 2.
- POON, W. P. H., M. FIRTH, H. G. FUNG (1999), “A Multivariate Analysis of the Determinants of Moody’s Bank Financial Strength Ratings”, *Journal of International Financial Markets, Institutions and Money*, Vol. 9, No. 3.
- RUMELHART D.E., J.L. MCCLELLAND, ve the PDP Group (1989), *Parallel Distributed Processing: Exploration in the Microstructure of Cognition*, Vol. 1, MIT Press, MA.
- SINGLETON, J. C., A. J. S. SURKAN, (1990), “Neural Network for Bond Rating Improved by Multiple Hidden Layers”, *Proceedings of the IEEE International Conference on Neural Networks*, Vol. 2, San Diego.
- TAN, R.P.G.H., J. VAN DEN BERG, W. M. VAN DEN BERGH (2002), “Credit Rating Classification Using Self Organizing Maps”, In: Smith, K., Gupta, J. (Eds.), *Neural Networks in Business: Techniques and Applications*, IDEA Group Publishing.
- TBB (Mayıs 2002-2006), *Bankalarımız 2001, 2002, 2003, 2004, 2005*, İstanbul.
- WEST, R. R. (1970), “An Alternative Approach to Predicting Corporate Bond Ratings”, *Journal of Accounting Research*, Vol. 8, No.1.
- WEST, D. (2000), “Neural Network Credit Scoring Models”, *Computers & Operations Research*, Vol. 27.

*Melek Acar Boyacıođlu-Yakup Kara*