

FİNANSAL BİLGİ MANİPÜLASYONUNUN TESPİTİNDE YAPAY SİNİR AĞI MODELİNİN KULLANIMI

Yrd.Doç.Dr. Güray KÜÇÜKKOCAOĞLU¹
Yrd.Doç.Dr. Yasemin KESKİN BENLİ²
Dr. Cemal KÜÇÜKSÖZEN³

ÖZET

Finansal bilgi manipülasyonunun tespitinde sıklıkla kullanılan tahakkuk esaslı modeller önemli eleştirilere maruz kalmaktadır. Tahakkuk esaslı yaklaşımlara karşı alternatif olarak kullanılan probit ve logit modellerin yanı sıra çok değişkenli, çok kriterli modeller finansal bilgi manipülasyonunun tespitinde tahakkukların yanı sıra, bir takım finansal oranları ve endeksleri de kullanılmaktadır. Bu çalışmanın amacı, finansal bilgi manipülasyonunun tespitinde kullanılan tahakkuk esaslı modellerin tarihsel gelişimini anlatmak, ardından ortaya çıkan diğer alternatif metodolojileri tanıtmaktır. Çalışmada aynı zamanda, finansal sıkıntıda bulunan firmaları tespit için kullanılan Yapay Sinir Ağı Modeli'nin finansal bilgi manipülasyonunun tespitine nasıl bir katkı sağlayacağı da tartışılmaktadır. Yapay sinirlerin kullanımına dayanan modelin İstanbul Menkul Kıymetler Borsası'nda (İMKB) yer alan şirketlerin finansal bilgi manipülasyonu uygulamalarını tespit etmek bakımından diğer modellerin bulgularıyla (bire bir karşılaştırma yapma imkânı bulunmasa da) karşılaştırıldığında daha iyi sonuçlar ürettiği gözlenmektedir.

Anahtar Kelimeler: Finansal Bilgi Manipülasyonu, Finansal Oranlar, Yapay Sinir Ağı Modeli.

ABSTRACT

Despite their widespread usage, models of accrual based methods in detecting false financial statements have been subject to significant criticism. An alternative to the accruals approach is to use binary probit and logit models and some other multivariate statistical techniques where they combine accruals and some other financial ratios and/or indexes. The objective of this paper is to explain the historical evolution of the accrual based methods where they provide some evidence of earnings management practices and then extend to some other alternative methods in detecting manipulative practices in financial reporting. This paper also, introduces a new method that has been widely used in detecting financial distress companies. An Artificial Neural Network Model, which is based on the concept of using artificial neurons, to estimate the manipulative financial reporting practices of the companies listed in the Istanbul Stock Exchange (ISE). The results indicate that the proposed Artificial Neural Network Model outperforms the traditional statistical techniques used in earnings manipulation practices.

Key words: Earnings Management, Financial Ratios, Artificial Neural Network Model.

¹ Başkent Üniversitesi, İktisadi ve İdari Bilimler Fakültesi, İşletme Bölümü B219, Bağlıca Kampüsü, 06530, Ankara – Türkiye + 90 (312) 234 10 10 / 1728, gurayk@baskent.edu.tr

² Gazi Üniversitesi, Endüstriyel Sanatlar Eğitim Fakültesi, İşletme Eğitimi Bölümü.

³ Sermaye Piyasası Kurulu, Muhasebe Standartları Dairesi Başkanı

1. Giriş

Finansal bilgi manipülasyonuna başvuran işletmeleri, halka açıkladıkları finansal bilgilerle, tespit etmek oldukça güçtür. Düzenleyici Kurullar kadar yetkisi olmayan ve şirket bilgilerine onlar kadar ulaşamayan akademisyenler ise, finansal bilgi manipülasyonuna başvuran işletmeleri tespit açısından bir takım modeller geliştirmeye çalışmaktadır. Literatüre sunulan modeller açıklama güçlerine göre finansal bilgi manipülasyonuna başvuran ve başvurmeyen işletme ayırımına giderek, manipüle edilmiş finansal bilgiyi ortaya çıkarmaya çalışmaktadır. Bu kapsamda ilk olarak Healy (1985) tarafından literatüre sunulan, yöneticilerin beklenmedik ihtiyari tahakkuk uygulamalarının ya da muhasebe politikası seçimlerinin etkilerini ölçen, model karşımıza çıkmaktadır. Healy'nin (1985) çalışmasını takip eden diğer modeller beklenmeyen ihtiyari tahakkukları ölçmek üzere toplam tahakkuklar üzerinde durmuşlar, kamuya açıklanan net kar ile faaliyetlerden sağlanan nakit arasındaki fark olarak belirlenen toplam tahakkukları tahmin etmeye çalışmışlardır. Bu şekilde tahmin edilen toplam tahakkuklar, normal tahakkukların bir göstergesi olarak kabul edilen; tipik işletme sermayesi ihtiyacını (ticari alacaklar, stoklar ve ticari krediler gibi) ortaya koymak üzere gelirler (ya da müşterilerden tahsil edilen nakit) ve normal amortismanları ortaya koymak üzere de brüt sabit varlıklar gibi değişkenlerle regresyona tabi tutulmuştur. Jones'a (1991) göre, bu regresyon işleminde beklenmeyen tahakkuklar, toplam tahakkukların açıklanamayan kısmını oluşturmaktadır (Küçüksözen ve Küçükkocaoğlu, 2005).

Yukarıda belirtildiği üzere, finansal bilgi manipülasyonunu ortaya çıkarmaya diğer bir ifadeyle, tahmin etmeye çalışan modellerde öncelikle toplam tahakkuklar üzerinde durulmaktadır. Bazı çalışmalarda doğrudan toplam tahakkuk tutarı, aktif toplamına veya satış hâsılatı tutarına endekslenmek suretiyle beklenmeyen diğer bir deyişle, işletme faaliyetinin gerektirdiğinin üzerindeki tahakkuk tutarı tahmin edilmeye çalışılmakta ve yıllar itibariyle ortaya çıkan anormal tahakkuk tutarları finansal bilgi manipülasyonunun göstergesi olarak dikkate alınmaktadır.

Bazı çalışmalarda ise toplam tahakkuklar, faaliyetlerin gerektirdiği (ihtiyari olmayan) ve gerektirmediği (ihtiyari) tahakkuk şeklinde ayrıştırılmakta ve ihtiyari tahakkuk tutarları şirketin aktif toplamına veya satış hâsılatı tutarına endekslenerek, bu endekste yıllar itibariyle ortaya çıkan eğilim, çeşitli amaçlara yönelik finansal bilgi manipülasyonunun göstergesi olarak kabul edilmektedir.

Tahakkuk esaslı hesaplamaların ardından literatürde yer alan diğer çalışmalar ise, daha çok Logit ve Probit modellere yer vermektedir. İlk olarak Beneish (1997) tarafından kullanılan ve finansal bilgi manipülasyonunu tespit etmeye yönelik bir denkleme ulaşılan modelin ardından, literatürde çeşitli modeller aracılığıyla manipülasyonu tespiti yönelik hesaplamalar yapıldığı gözlemlenmektedir. Çalışmamızda bu alana katkı sağlamak amacıyla Yapay Sinir Ağı'na dayalı bir tespit yönteminin, özellikle Beneish (1997) tarafından kullanılan endekslerin İMKB şirketleri üzerine uygulandığında, nasıl bir sonuca ulaşabileceği test edilmiştir.

Sinir ağlarının finansal bilgi manipülasyonunun tespitinde kullanımına yönelik ilk çalışma Fanning, Cogger ve Srivastava (1995) tarafından yapılmıştır. Ardından Fanning and Cogger (1998) ilk çalışmalarında kullandıkları veri setinin kapsamını değiştirerek toplam 20 değişken arasından 8 değişkenin (ticari alacaklar/satışlar, ticari alacaklar/toplam varlıklar, stoklar/satışlar, duran varlıklar/toplam varlıklar, toplam borçlar/sermaye, satışlar/toplam varlıklar) finansal bilgi manipülasyonunun tespitinde anlamlı bir açıklama gücüne sahip

olduğunu göstermiştir. İlerleyen bölümlerde açıklanacağı üzere benzer oranları logistic regresyon yöntemiyle Atina Menkul Kıymetler Borsası'nda test eden Spathis (2002) ve İstanbul Menkul Kıymetler Borsası'nda test eden Küçüksözen ve Küçükkocaoğlu'nun çalışmalarında (2005) bu tür finansal oranların finansal bilgi manipülasyonunu açıklamada çok da başarılı olmadığını, aksine Beneish (1997) tarafından önerilen endekslerin ise daha anlamlı açıklama gücüne sahip olduğu görülmektedir.

Çalışmanın bundan sonraki bölümünde finansal bilgi manipülasyonunun tespitine yönelik tahakkukları esas alan modellere değinilecek, ardından alternatif yaklaşımlar sunan özellikle finansal tablolaradaki bilgilere dayalı analizler yapılan çeşitli modeller tanıtılacaktır. Üçüncü bölümde ise, finansal bilgi manipülasyonunun tespitinde yapay sinir ağı modelinin uygulanması ampirik bir çalışmayla gösterilecektir. Dördüncü ve son bölümde çalışmanın sonuçları özetlenmektedir.

2. Finansal Bilgi Manipülasyonunun Ortaya Çıkarılması ile ilgili Modeller

Çalışmanın bu bölümünde finansal bilgi manipülasyonunun tespitine yönelik Healy (1985) tarafından literatüre sunulan, ardından birçok akademisyen tarafından çalışma konusu olan tahakkukları esas alan modellere değinilecek, daha sonra bir takım alternatif yaklaşımlar içeren finansal oranları ve endeksleri kullanarak finansal bilgi manipülasyonunun tespitini amaçlayan modeller tanıtılacaktır.

2.1. Tahakkuk Esaslı Modeller

İlk olarak Healy (1985) tarafından literatüre sunulan, ardından DeAngelo (1986), Jones (1991) tarafından geliştirilen tahakkuk esaslı modellerde, zamanla farklı isimler altında farklı hesaplama yöntemleri birer ölçüm aracı olarak kullanılmıştır. Çalışmanın bu bölümünde Healy (1985) ile başlayan ardından gelişen tahakkuk esaslı modellere değinilmektedir.

2.1.1. Healy Modeli

Healy (1985) çalışmasında, teşvik primleri ile ödüllendirilen yöneticilerin alacakları teşvik primi tutarlarını artırmak için toplam tahakkukları kullanarak finansal bilgi manipülasyonu yaptıkları hipotezini ortaya atmış ve bunu aşağıdaki modeli kullanarak test etmiştir.

$$NDA_t = 1/n \sum_{\tau} (TA_{\tau} / A_{\tau-1})$$

NDA = İhtiyari tahakkukları
TA = Toplam tahakkuklar
A = Toplam varlıklar

2.1.2. DeAngelo Modeli

DeAngelo (1986) çalışmasında, halka açık bir şirketin yatırımcıların elindeki hisse senetlerini geri alarak halka kapalı özel bir şirket statüsüne getirilmesi sırasında, yöneticilerin hisse senetlerinin değerini düşük göstermek amacıyla finansal bilgi manipülasyonu (kar yönetimi) yaptıkları hipotezini aşağıdaki modeli kullanarak test etmiştir.

$$NDA_t = TA_{t-1} / A_{t-2}$$

NDA = İhtiyari tahakkukları
TA = Toplam tahakkuklar
A = Toplam varlıklar

2.1.3. Jones Modeli

Jones (1991) çalışmasında, ABD'deki şirketlerin buldukları sektördeki gümrük tarifelerinin yükseltilmesi ya da kotaların kısıtlanması gibi gümrük korumalarından yararlanmak için, ABD Ticaret Komisyonu tarafından inceleme yapılan dönemde, finansal bilgi manipülasyonu (kar yönetimi) ile karlarını düşük gösterip göstermediklerini aşağıdaki modeli kullanarak test etmiştir.

$$TA_{it} / A_{it-1} = \alpha_i [1/A_{it-1}] + \beta_{1i} [\Delta REV/A_{it-1}] + \beta_{2i} [PPE/A_{it-1}] + \varepsilon_{it}$$

TA = Toplam tahakkuklar,
A = Toplam Varlıklar,
 ΔREV = Gelirlerdeki değişim,
PPE = Brüt maddi duran varlıklar.

2.1.4. Düzeltilmiş Jones Modeli

Jones (1991) modelinde zımni olarak, gerek finansal bilgi manipülasyonunun yapıldığı dönemde ve gerekse tahmin döneminde ihtiyari tahakkuk kararlarının satış gelirleri ile ilgili olmadığı varsayımı yapılmaktadır. Dechow, Sloan ve Sweeney'e (1995) göre ise model, yöneticiler tarafından finansal bilgi manipülasyonunun gelirler üzerinden yapılması halinde ihtiyari tahakkukları hatalı olarak ölçmekte, dolayısıyla bu varsayım modelde ihtiyari tahakkukların hesaplanmasında sorun yaratmaktadır. Bu kapsamda, tahakkukların hesaplanmasında sadece gelirlerdeki değişimin kullanılması yerine, gelirlerdeki değişimin alacaklardaki net değişimden (içinde bulunulan yıldaki alacaklar – bir önceki yıldaki alacaklar) çıkartılmak suretiyle kullanılması, diğer bir ifade ile gelirlerdeki değişimin alacaklardaki değişim dikkate alınarak bir ayarlamaya tabi tutulması yöntemine başvurulmuştur. Dolayısıyla düzeltilmiş Jones modelinde, kredili satışlar tutarındaki bütün değişimlerin finansal bilgi manipülasyonundan kaynaklandığı zımni olarak varsayılmaktadır. Bu varsayım, kredili satışlarda gelirin tanımlanması hususunda takdir hakkı kullanmanın nakit satışlarda gelirin tanımlanmasına göre daha kolay uygulanabileceği, dolayısıyla kredili satış işlemleri ile finansal bilgi manipülasyonunun daha kolay gerçekleştirilebileceği kabulüne dayanmaktadır (Küçüksözen ve Küçükkocaoğlu, 2005).

$$NDA_t = \alpha_1(1/ TA_{t-1}) + \alpha_2[(\Delta REV_t - \Delta REC_t) / TA_{t-1}] + \alpha_3(PPE_t / TA_{t-1})$$

NDA = İhtiyari tahakkukları
TA = Toplam Varlıkları,
 ΔREV = Gelirlerdeki değişimi,
 ΔREC = Alacaklardaki değişimi,
PPE = Brüt maddi duran varlıkları göstermektedir.

2.1.5. Endüstri Modeli

Jones (1991) modeline paralel olarak, Endüstri modeli, ihtiyari olmayan tahakkukların bütün dönemlerde sabit olduğu varsayımını gevşetmekte, bununla birlikte, ihtiyari tahakkukların

belirleyicilerini doğrudan modellemek yerine, bu belirleyicilerdeki değişimin aynı sektördeki bütün şirketlerde aynı olduğu varsayımından hareket etmektedir. Yöntem, incelemeye alınan örnek şirketler dışında aynı sektörde yer alan şirketlerin aktif büyüklüğüne göre ölçeklendirilmesi suretiyle hesaplanan toplam tahakkuk oranlarının medyan değerlerinin kullanılmasına dayanmaktadır.

$$NDA_t = \beta_1 + \beta_2 \text{median}_j (TA_t/A_{t-1})$$

NDA_t = İhtiyari tahakkuklar

TA = Toplam Varlıklar.

Dechow, Sloan ve Sweeney (1995), yukarıda belirtilen tahakkuk bazlı finansal bilgi manipülasyonunu ortaya çıkarmaya yönelik modelleri test etmişlerdir. Yaptıkları çalışma sonucuna göre, Düzeltilmiş Jones Modeli finansal bilgi manipülasyonunun ortaya çıkarılması açısından yukarıdaki modellere göre en güçlü model olarak ortaya çıkmaktadır (Küçüksozen ve Küçükkocaoğlu, 2005).

2.2. Karma Modeller

Karma modeller, içlerinde toplam tahakkukları barındırmakla birlikte, genelde finansal bilgi manipülasyonu uygulamalarında kullanılan muhasebe hesaplarını bir takım finansal oranlara ve endekslere çevirerek tespit etmeye çalışmaktadır.

2.2.1. Logit ve Probit Modeller

Özellikle Beneish'in (1997) öncülüğünde finansal bilgi manipülasyonu yapan işletmelerin tespitine yönelik farklı bir bakış açısı gelmiştir. Tahakkuklarda değişimi tespit için kullanılan doğrusal regresyonların yanı sıra, tahakkuklara ek olarak bir takım farklı değişkenlerin de kullanıldığı probit ve logit modellerin finansal bilgi manipülasyonuna başvuran işletmelerin tespitinde kullanılabileceğini söyleyen Beneish, 1997 ve 1999 yıllarında yaptığı çalışmalarda finansal bilgi manipülasyonu literatürüne yeni bir boyut kazandırmıştır.

2.2.1.1. Beneish Modeli (Probit Model)

Beneish (1997), (1999) oluşturduğu modelde, finansal bilgi manipülasyonuna başvuran işletmelerin her zaman agresif olarak tahakkuk kullanan şirketler olmadığını, finansal bilgi manipülasyonunu tespit için bir takım farklı değişkenlerin de kullanılması gerektiğini söylemektedir. Bu değişkenler, finansal tablolarda yer alan bilgilerden üretilen ve gerçekleştirilen finansal bilgi manipülasyonlarını ortaya çıkaracak nitelikte olup, işletmelerin genel kabul görmüş muhasebe standartlarına aykırı işlem yapma durumunu tespitiye yöneliktir.

Modelde, finansal bilgi manipülatörü şirketlerle, finansal bilgi manipülasyonu yapmadığı kabul edilen kontrol şirketlerinin aşağıda belirtilen açıklayıcı değişkenler şeklindeki finansal verileri probit analize tabi tutulmaktadır. Probit analiz, aşağıdaki denklemde yer alan bağımlı değişkenlerin (M_i ; ikili değişken; manipülatörler için 1, kontrol şirketleri için 0 değerini almaktadır) kullanıldığı olaylar için uygun olduğu kabul edilen bir regresyon analizi türüdür.

Beneish (1997), (1999) modelinde; finansal bilgi manipülatörü şirketlerle kontrol şirketlerinin verilerini probit analize tabi tutarak her bir değişken için katsayılar bulmaktadır. Bu katsayıları kullanarak her bir şirketin finansal bilgi manipülasyonu yapıp yapmadığını, M_i

sonucunun 0 (sıfır)'a yakın olması halinde manipülatör değil, 1'e yakın olması halinde manipülatör şeklinde değerlendirmek üzere model çerçevesinde hesaplamaktadır.

Bu çerçevede Beneish (1997), (1999) Modeli (Probit Model);

$$M_i = \beta^i X_i + \epsilon_i$$

şeklinde olup burada;

M_i = Kukla değişkeni (İkili değişken; Finansal bilgi manipülasyonu yapan şirketler için 1 değeri almakta, finansal bilgi manipülasyonuna başvurmeyan şirketler için 0 değerini almaktadır),

β^i = Model çerçevesinde her bir bağımsız değişken için bulunan katsayıyı,

X_i = Açıklayıcı değişkenlerin oluşturduğu matrisi,

ϵ_i = Hata terimini ifade etmektedir.

Modelde kullanılan önemli açıklayıcı (bağımsız) değişkenler aşağıda açıklanmıştır.

- Ticari alacaklar endeksi,
- Brüt kâr marjı endeksi,
- Aktif kalitesi endeksi,
- Amortisman endeksi,
- Pazarlama, Satış, Dağıtım ve Genel Yönetim Giderleri endeksi,
- Toplam Tahakkukların Toplam Varlıklara Oranı,
- Satışlardaki yıllık değişim,
- Stoklardaki Değişim endeksi,
- Hisse senetleri fiyatlarındaki yıllık değişim.

Dechow, Sloan ve Sweeney'e (1996) göre, Beneish'in (1997) modeli Jones (1991) modelindeki gibi sadece ticari alacaklar üzerinden gerçekleştirilecek finansal bilgi manipülasyonları yanında, bir şirketin finansal durum ve performansı ile ilgili değişik görünümüleri ele alarak finansal tablo kullanıcılarının şirketi değişik açılardan gözden geçirebilmelerine imkan sağlamaktadır. Ayrıca modelde kullanılan değişkenler hem şirketin gerçekleştirdiği manipülatif işlemleri tespitiye yönelik, hem de şirketin manipülatif işlemleri gerçekleştirme niyetini kavramaya yöneliktir.

Diğer taraftan Beneish'e (1997) göre, kendi modeli, Jones'un (1991) tahakkuk modelini güçlendirmektedir. Bu kapsamda model büyük tutarlarda ihtiyari tahakkuk kullanan şirketlerdeki olası finansal bilgi manipülasyonu (kâr yönetimi) uygulamalarını da doğru bir şekilde ortaya koymaktadır. Zira ihtiyari tahakkuklar finansal bilgi manipülasyonu için yapılabileceği gibi, bundan bağımsız olarak şirketin stratejik hedeflerine yönelik faaliyet kararlarına dayalı olarak da yapılabilmektedir.

2.2.1.2. Spathis Modeli (Logit Model)

Beneish'in (1997), (1999) probit modelinde kullanılan endekslerden farklı olarak finansal oranlara çalışmasında yer veren Spathis (2002), yine finansal bilgi manipülasyonunu tespit ederken probit yerine logistic regresyon analizine başvurmuştur. Spathis (2002) tarafından aşağıdaki denkleme göre oluşturulan model, finansal bilgi manipülatörü şirketlerle kontrol şirketlerini aşağıda açıklanan bağımsız değişkenlere göre logistic regresyon analizine tabi tutmaktadır.

$$E(y) = \frac{\exp(b_0 + b_1x_1 + b_2x_2 + \dots + b_nx_n)}{1 + \exp(b_0 + b_1x_1 + b_2x_2 + \dots + b_nx_n)}$$

Denklemden; bağımlı değişken E(y)'ye gerçeğe aykırı finansal bilgi açıklayan şirketler için 1, kontrol şirketleri için 0 değeri verilmiş olup, b_0 kesişim değerini, b_1, b_2, \dots, b_n bağımsız değişkenlerin katsayılarını, x_1, x_2, \dots, x_n ise aşağıdaki bağımsız değişkenleri göstermektedir.

$$\text{FFS} = b_0 + b_1(\text{D/E}) + b_2(\text{Sales/TA}) + b_3(\text{NP/Sales}) + b_4(\text{Rec/Sales}) + b_5(\text{NP/TA}) + b_6(\text{WC/TA}) + b_7(\text{GP/TA}) + b_8(\text{INV/Sales}) + b_9(\text{TD/TA}) + b_{10}(\text{FE/GE}) + b_{11}(\text{Taxes/Sales}) + b_{12}(\text{Altman Z-score})$$

- Borç özsermaye oranı (D/E),
- Satışların toplam aktiflere oranı (Sales/TA),
- Net karın satışlara oranı (NP/Sales),
- Ticari alacakların satışlara oranı (Rec/Sales),
- Net karın aktife oranı (NP/TA),
- Çalışma sermayesinin toplam aktife oranı (WC/TA),
- Brüt karın toplam aktife oranı (GP/TA),
- Stokların satışlara oranı (INV/Sales),
- Toplam borçların toplam aktiflere oranı (TD/TA),
- Toplam finansman giderlerinin toplam faaliyet giderlerine oranı (FE/GE),
- Ödenecek vergi ve diğer yasal yükümlülüklerin toplam satışlara oranı (Taxes/Sales) ve
- Finansal risk skoru'nu (Altman Z-score),

göstermektedir.

2000 yılında Atina Menkul Kıymetler Borsasında işlem gören 76 şirketin finansal tablo verilerini kullanarak logistic regresyon analizi yapan Spathis (2002), bir takım finansal tablo değerlerini kullanarak gerçeğe aykırı finansal tabloları tespit ederken bakılması gereken rasyoları tespit etmeye çalışmıştır. Bu oranların; stokların satışlara oranı (INV/Sales), toplam borçların toplam aktiflere oranı (TD/TA) ve Altman Z Score'u olduğu yönünde tespitlerde bulunmuştur.

Benzer bir çalışmayı İstanbul Menkul Kıymetler Borsası'nda işlem gören şirketler üzerine yapan Küçüksözen ve Küçükkocaoğlu'nun (2005) bulguları, gerçeğe aykırı finansal tablolar tespit edilirken bakılması gereken rasyoların; net kârın toplam aktife oranı ve toplam finansman giderlerinin toplam faaliyet giderlerine oranı olduğunu göstermektedir.

2.2.2. Çok Değişkenli, Çok Kriterli Modeller

Finansal yönetim, iflas öngörüsü, kredi riski ölçümleri, ülke riski hesaplamaları, portföy seçimi ve yönetimi gibi, bir çok alanda kullanılan UTADIS metodolojisi Spathis, Doumpos ve Zopounidis (2004) tarafından finansal bilgi manipülasyonunu tespit için kullanılmıştır. Spathis'in (2002) Logit Modelinde yer alan değişkenleri kullanarak bir fayda fonksiyonu oluşturan Spathis, Doumpos ve Zopounidis (2004), fonksiyonun alt ve üst sınırlarını belirledikten sonra finansal bilgi manipülasyonuna başvuran ve başvurmeyen şirketlerin ayrımını yapmaya çalışmışlardır. Başarı oranlarını her ne kadar yüzde 100 olarak belirleseler de, uyguladıkları metodoloji, hesaplamalarda kullanılan veri setinin küçüklüğü ve kapsamı dikkate alındığında çalışma sonuçlarının yanıltıcı bir yapıya sahip olduğu kanaatine sahibiz.

3. Finansal Bilgi Manipülasyonunun Tespitinde Yapay Sinir Ağı Modeli

Son yıllarda bilgisayar teknolojisi büyük bir hızla gelişmekte, işlem hızı ve kapasitesi çok yüksek bilgisayarların üretimi mümkün olmaktadır. Çok karmaşık hesaplamaların göz açıp kapayıncaya kadar yapılmasına olanak tanıyan bu yüksek teknolojiye rağmen, insanların çok kolaylıkla yerine getirebildiği el yazısını tanıma, konuşmayı tanıma ve görme gibi işlevlerin bilgisayarlar tarafından otomatik olarak gerçekleştirilmesi konusunda yetersizlik söz konusudur. Bu gerçek, bilim insanlarını klasik anlamdaki bilgisayarlardan farklı alternatif bilgi işleme sistemleri geliştirmeye yöneltmiş, doğal olarak bu konudaki ilk adımlardan biri de insan beyninin çalışmasıyla ilgili birtakım biyolojik bulgulardan faydalanmaya çalışmak olmuştur. Nörofizyologların ve psikologların çalışmalarından elde edilen sonuçlardan faydalanarak insan beynindeki sinir ağlarının yapısal ve işlevsel özelliklerinin basite indirgenip matematiksel olarak modellenmesine çalışılmıştır. Bu matematiksel modellere sinir ağları denmektedir (Sungur, 1995).

Yapay sinir ağları çok değişkenli ve değişkenler arasında karmaşık, karşılıklı etkileşimin bulunduğu veya tek bir çözüm kümesinin bulunmadığı durumlarda başarılı sonuçlar üreten bir yapay zeka teknolojisidir. Bu özellikleri nedeniyle yapay sinir ağı teknolojisi finansal başarısızlık alanında kullanıma uygun bir araç olarak görülmektedir (Salchenberger, Çınar ve Lash, 1992; Wilson ve Chong, 1995; Koh ve Tan, 1999; Yıldız, 2001).

Yapay sinir ağı araştırmaları nörofizyolog ve psikolog için insan beyninin işlevlerini açıklayabilme amacına yöneliktir. Mühendisler açısından ise, yapay sinir ağları öncelikle alternatif bir hesaplama aracıdır. Ancak bu iki araştırma motivasyonu arasında sıkı bir bağ vardır. Nörofizyolojik bulgular yeni matematiksel modellerin geliştirilmesi için esin kaynağı teşkil ederken, geliştirilen matematiksel modeller üzerinde yapılan çalışmaların ve uygulamaların sonuçları da nörofizyolojik araştırmalara yön verebilecek niteliktedir.

İlk ticari yapay sinir ağının geliştiricisi olan Robert Hecht-Neilsen (1989), yapay sinir ağını “dışarıdan gelen girdilere dinamik olarak yanıt oluşturma yoluyla bilgi işleyen, birbiriyle bağlantılı basit elemanlardan oluşan bilgi işlem sistemi” olarak tanımlamaktadır (Yıldız, 2001). Başka bir ifade ile yapay sinir ağları, her biri kendi belleğine sahip olan, işlem yapabilen ve tek yönlü sinyal kanalları ile birbirlerine bağlanmış birçok basit işlem elemanından (yapay nöron) oluşan, paralel ve dağınık tek veya çok katmanlı bir bilgi işlem sistemi olarak tanımlanır (Gülseçen, 1995).

Bir yapay sinir ağının yapısında, birbirleriyle bağlantılı sinirlerin yer aldığı girdi katmanı, çıktı katmanı ve gizli katman olmak üzere temelde üç katman bulunmaktadır.


Girdi katmanı ilk katmandır ve dışarıdan gelen verilerin yapay sinir ağına alınmasını sağlar. Bu veriler istatistikte bağımsız değişkenlere karşılık gelir. Son katman çıktı katmanı olarak adlandırılır ve bilgilerin dışarıya iletilmesi işlevini yapar. Çıktı değişkenleri de istatistikte bağımlı değişkenlere karşılık gelir. Modeldeki diğer katmanlar ise, girdi katmanı ile çıktı katmanı arasında yer alır ve gizli katman olarak adlandırılır. Gizli katmanda bulunan sinirlerin dış ortamla bağlantıları yoktur. Yalnızca girdi katmanından gelen sinyalleri alırlar ve çıktı katmanına sinyal gönderirler.

Gizli katmandaki gizli nöronların sayısının seçimi oldukça önemlidir. Ağın büyüklüğünün tanımlanması, ağın performansının bilinmesi açısından önem taşımaktadır. Gizli nöronların ve

katmanlarının sayısının artırılması ya da azaltılması, ağına basit ya da karmaşık bir yapıda olmasını etkilemektedir.

Bir yapay sinir ağındaki en önemli unsurlardan biri de nöronların birbirlerine veri aktarmalarını sağlayan bağlantılardır. Herhangi bir (i) nöronundan (j) nöronuna bilgi ileten bir bağlantı, aynı zamanda bir ağırlık (w_{ji}) değerine sahiptir. Ağırlıklar bir nöronda girdi olarak kullanılacak değerlerin göreceli kuvvetini gösterir. Yapay sinir ağı içinde tüm bağlantıların farklı ağırlık değerleri bulunmaktadır. Böylelikle ağırlıklar her işlem elemanının her girdisi üzerinde etki yaparlar (Yıldız, 2001).

Şekil 1’de verilen yapay sinir ağı yapısında X ile girdiler, h ile gizli katmandan gelen çıktılar ve Y ile de sonuçta elde edilen çıktılar gösterilmiştir (Güneri, 2001).



Şekil 1. Yapay Sinir Ağı Yapısı

Yapay sinir ağı modelinde sinirler arasındaki bağlantıların ağırlık değerleri uygulamanın başında SPSS paket programında tesadüfi olarak üretilir. Ağ, bu değerler kullanılarak test edilmektedir.

Veri setinde yer alan veriler tesadüfi olarak eğitim, geçerlilik ve test seti olmak üzere üç bölüme ayrılmaktadır. Eğitim seti, ağına eğitime yönelik olarak verilerin ağırlıklarına uygun olan öğrenme için kullanılmaktadır. Geçerlilik seti, bir sınıflandırıcının ağırlıklarına uygun olarak kullanılır. Örneğin, yapay sinir ağındaki gizli katman sayısını seçmek için geçerlilik seti kullanılır. Test seti ise, eğitimin uygulanmasının performansını ölçmede kullanılır. Veri setinin % 80’ini eğitim seti, % 10’unu geçerlilik seti, % 10’unu da test seti oluşturmaktadır.

Veriler karar ya da önerilere eşit katkıda bulunduğundan ölçü birimi etkisinden arındırılmak için standartlaştırılır. Kullanılan paket program ilk aşamada verileri standartlaştırır. Daha sonra geçiş fonksiyonu seçilir. Bu çalışmada geçiş fonksiyonu sigmoid fonksiyon olarak seçilmiştir.

Gerçek çıktı değerleri ile arzu edilen çıktı değerleri arasındaki farklılık ölçülür ve sonuca göre ağ modelinin bağlantı ağırlıkları değişir. Bağlantı ağırlıkları sonucu oluşan geri dönüş geçişi çıktı katmanlarının bağlantıları ile başlayan ve girdi katmanlarının bağlantıları ile sona eren ağın üretilmesiyle gerçekleşir.

Bir katmandaki sinir sayısı ağlar tarafından otomatik olarak seçilebilir ya da bağlantılı olarak düzenlenebilir. Birçok durumda sinirlerin sayısını artırmak eğitim verileri üzerindeki çoklu katman ağlarının performansını geliştirir.

Bir problemdeki gizli katmanların sayısının etkisini değerlendirmek için geçerlilik verilerinin performansına bakılır. Ağ yapısının performansını ölçmek için mutlak hata ortalaması (M.H.O) ve hata kareler ortalaması (H.K.O) kullanılmaktadır. Buna göre, mutlak hata ortalaması ve hata kareler ortalamasının en küçük olduğu değer, alınması gereken gizli katman sayısını belirlemektedir. Mutlak hata ortalamasına göre, gizli katman sayısı 6, hata kareler ortalamasına göre de gizli katman sayısı 4 olarak belirlenmiştir. Bu seçilen gizli katmanlı modellerin yapay sinir ağı uygulamasına göre sınıflandırma tabloları elde edilmiştir.

Yapay sinir ağı uygulamasında kopuş değeri 0.5 olarak belirlenmiştir. Buna göre hesaplanan olasılık değeri 0.5' ten büyük olan şirketler finansal bilgi manipülasyonu yapan şirketler, hesaplanan olasılık değeri 0.5' ten küçük olan şirketler ise finansal bilgi manipülasyonu yapmayan şirketler sınıfına ayrılmaktadır. Gözlemler sınıflandırılarak bölümlendirildikten sonra, gerçek durumlarıyla karşılaştırılarak doğru sınıflandırma oranları hesaplanmaktadır.

Ağın eğitimi için 10.000 iterasyon gerçekleştirilmiştir. Yapay sinir ağı analizi sonucunda eğitim, geçerlilik ve test seti için doğru sınıflandırma tabloları, bu sonuçlar birleştirilerek yapay sinir ağı uygulamasına göre sınıflandırma tablosu elde edilmiştir.

3.1. Analiz Kapsamındaki Şirketler

Çalışmamızda İMKB'de hisse senetleri işlem gören ve reel sektörde faaliyet gösteren 126 şirket, örnek şirket olarak seçilmiştir. Bankalar, sigorta şirketleri ve diğer finans sektöründe faaliyet gösteren şirketler, konuya ilişkin diğer çalışmalarda olduğu gibi çalışmamız kapsamının dışında tutulmuş olup, çalışma kapsamındaki şirketlerin 1992-2002 yıllarına ilişkin bilanço ve gelir tabloları analiz edilmiştir.

Çalışma kapsamında yer alan 126 şirketin 1992-2002 yıllarına ait finansal tablolarını inceleyen Sermaye Piyasası Kurulu, şirketlerin geçen süre zarfında 168 kez finansal bilgi manipülasyonuna başvurduğunu, 1.040 gözlemde ise finansal bilgi manipülasyonunun tespit edilmediğini gözlemlemiştir. Finansal bilgi manipülasyonu yapan ve yapmayan şirket ayrımı yapabilmek için İMKB'nin 01.01.1992- 31.07.2004 tarihleri arasındaki günlük bültenleri ve SPK'nın 01.01.1996-31.07.2004 tarihleri arasında yayınlanan haftalık bültenleri bazı anahtar kelimelerden (finansal tablo, mali tablo, bilanço, gelir tablosu, kar, zarar, gelir, gider, bağımsız denetim raporu, aktifleştirme, düzeltme) yararlanılarak incelenmiştir. Bu bültenlerde yer alan bilgiler çerçevesinde, SPK tarafından yapılan denetim ve incelemeler sonucunda finansal bilgi manipülasyonu yaptığı belirlenerek kamuya açıklanan ve/veya bağımsız denetim raporlarında kamuya açıklanan finansal tablolardaki tutarları değiştirecek şekilde şartlı görüş bulunan ya da finansal tablolarında yer alan tutarları daha sonra yaptıkları açıklamalarla değiştiren şirketler finansal bilgi manipülasyonu yapan şirket olarak kabul edilmiştir. Bunlara ilave olarak, SPK'ya yapılan kayda alma başvurularında finansal tablolarının incelenmesi sırasında, bu tablolarda yer alan finansal bilgiler değiştirilerek

kamuya açıklanan şirketler de finansal bilgi manipülasyonu yapan şirket olarak dikkate alınmıştır.

Kontrol seti olarak belirlenen 1.040 gözlemde, SPK tarafından denetlenmediği ya da bağımsız denetim sırasında tespit edilemediği, dolayısıyla finansal bilgi manipülasyonu uygulamasına gittiği halde bu durum herhangi bir şekilde tespit edilerek kamuya açıklanmadığı için, gerçekte manipülatör olan şirketler de bulunabilir. Bununla birlikte, bu durum her modelin oluşturulmasında olduğu gibi çalışmamızda tip 1 hata olarak dikkate alınmıştır.

3.2. Değişkenlerin Tanımı ve Veri Kaynakları

Çalışmada kullanılan endeksler ve finansal oranlar⁴

- i. Satışlardaki büyüme endeksi (SBE)
- ii. Ticari alacaklar endeksi (TAE),
- iii. Brüt kar marjı endeksi (BKM),
- iv. Aktif kalitesi endeksi (AKE),
- v. Amortisman endeksi (AME),
- vi. Pazarlama, satış, dağıtım ve genel yönetim giderleri endeksi (PSE),
- vii. Kaynak yapısındaki değişim endeksi (KYE),
- viii. Toplam tahakkukların toplam varlıklara oranı (TVE),
- ix. Finansman giderlerinin satışlara oranı (FSE) ve
- x. Stokların satışlara oranı (SSE),

olarak tespit edilmiştir.

Önceki paragraflarda da değindiğimiz üzere Beneish (1997), (1999), finansal bilgi manipülasyonuna başvuran şirketlerin her zaman agresif olarak tahakkuk kullanan şirketler olmadığını, finansal bilgi manipülasyonunu tespit için bir takım farklı değişkenlerin de kullanılması gerektiğini söylemektedir. Bu değişkenler, finansal tablolarda yer alan bilgilerden hareketle gerçekleştirilen manipülasyonları ortaya çıkaracak nitelikte olup şirketlerin genel kabul görmüş muhasebe ilkelerine aykırı işlem yapma durumunu tespitte yöneliktir.

Bu bağlamda çalışmamız için seçilen bağımsız değişkenler esas olarak Beneish (1997), (1999) modelinde kullanılan bağımsız değişkenlerle aynıdır. Bu değişkenler yanında, Küçüksözen ve Küçükkocaoğlu (2005) tarafından oluşturulan modelde yer alan “stokların satışlara oranı (SSE)” ve “finansman giderlerinin satışlara oranı (FSE)” bağımsız değişkenlerine de çalışmamızda yer verilmiştir.

Yapay sinir ağı analizi için Neural Connection paket programından yararlanılmıştır.

3.3. Ampirik Sonuçlar

Yapay sinir ağı analizinde problemin modeli, 10 bağımsız değişken olduğu için 10 girdi katmanından, diğer bir ifade ile değişkenlerin tanımı ve veri kaynakları kısmındaki, kullanılan endeksler ve finansal oranlardan oluşmaktadır, dolayısıyla girdi katmanında 10 sinir bulunmaktadır. Çıktı katmanında ise, finansal bilgi manipülasyonu yapan ve yapmayan

⁴ Endekslerin ve oranların hesaplamalarının nasıl yapıldığına dair açıklamaya çalışmanın ekinde yer verilmiştir.

şirketler olduğu için 1 çıktı katmanı söz konusudur, dolayısıyla çıktı katmanında da 1 sinir bulunmaktadır.

Gizli katman sayısını belirlemek için uygulamada önce gizli katman sayısı 1 alınarak 10-1-1 modeli için hatalar hesaplanmıştır. Daha sonra gizli katmanların sayısı artırılmış ve geçerlilik verilerine ilişkin hata kareler ortalaması (H.K.O) ve mutlak hata ortalaması (M.H.O) hesaplanmıştır. Bu sonuçlar aşağıdaki tabloda verilmiştir.

Tablo 1. Gizli Katman Sayısının Belirlenmesinde Oluşturulan Modellerin Sonuçları

Model	H.K.O	M.H.O
10-1-1	0.305868	0.208335
10-2-1	0.307067	0.211865
10-3-1	0.306856	0.211334
10-4-1	0.304201	0.210488
10-5-1	0.307615	0.208804
10-6-1	0.304297	0.206663
10-7-1	0.307096	0.209142

Tablo 1 incelendiğinde, 1 gizli katmanlı modelin (10-1-1) hata kareler ortalamasının 0.305868 olduğu görülmektedir. Gizli katman sayısı arttırıldığında hata kareler ortalaması 4. gizli katmandan sonra artmaktadır. Bu durumda tahmin modelinin oluşturulmasında, hata kareler ortalamasının en düşük olduğu katman olan 4 gizli katmanlı model (10-4-1) seçilmiştir.

Mutlak hata ortalamasına baktığımızda ise, 1 gizli katmanlı modelin (10-1-1) mutlak hata ortalamasının 0.208335 olduğu görülmektedir. Mutlak hata ortalamasının en düşük olduğu katman olan 6 gizli katmanlı model (10-6-1 modeli) en küçük hata değerine sahip olduğundan model olarak seçilmiştir.

Gizli katmanların sayısı arttırıldığında, her bir yeni gizli katman veri setindeki özelliklerden birini daha göstermeye başlayacağından geçerlilik setindeki ağ performansı da artmaktadır. Çok sayıda tabaka eklendiğinde performansta bir azalma görülebilir. Bunun nedeni genel güçteki kayıptır ve bu durumda ağ verilerinden gürültü öğrenmeye başlar. Geçerlilik seti üzerinde hata ölçümleri yapılarak aşırı öğrenmenin tehlikesi azaltılmış olur (Neural Connection, 1997; Güneri, 2001).

Ağın eğitimi için 10.000 iterasyon gerçekleştirilmiştir. Veri setinin % 80'ini eğitim seti, % 10'unu geçerlilik seti, % 10'unu da test seti oluşturmaktadır. Buna göre 966 veri eğitim setine, 121 veri geçerlilik setine ve 121 veri de test setine tabi tutulmuştur. Tahmin modelinin oluşturulmasında 4 gizli katmanlı model (10-4-1) ile 6 gizli katmanlı model (10-6-1) eğitim, geçerlilik ve test setine tabi tutularak sınıflandırma tabloları belirlenmiştir. Sonuçlar aşağıdaki tablolarda verilmiştir.

3.3.1. Dört Gizli Katmanlı Modelin Sonuçları

Tablo 2. Modelin Eğitim Seti İçin Sınıflandırması
(10-4-1)

Gerçek \ Tahmin	Finansal bilgi manipülasyonu yapmayan (0)	Finansal bilgi manipülasyonu yapan (1)	Toplam
Finansal bilgi manipülasyonu yapmayan (0)	831	1	832
Finansal bilgi manipülasyonu yapan (1)	132	2	134
Toplam	963	3	966

Eğitim seti için doğru sınıflandırma yüzdesi 86.231888 olarak bulunmuştur. Hatalı sınıflandırma yüzdesi ise 13.768116'dır.

Tablo 3. Modelin Geçerlilik Seti İçin Sınıflandırması
(10-4-1)

Gerçek \ Tahmin	Finansal bilgi manipülasyonu yapmayan (0)	Finansal bilgi manipülasyonu yapan (1)	Toplam
Finansal bilgi manipülasyonu yapmayan (0)	108	0	108
Finansal bilgi manipülasyonu yapan (1)	13	0	13
Toplam	121	0	121

Geçerlilik seti için doğru sınıflandırma yüzdesi 89.256195 olarak bulunmuştur. Hatalı sınıflandırma yüzdesi ise 10.743802'dir.

Tablo 4. Modelin Test Seti İçin Sınıflandırması
(10-4-1)

Gerçek \ Tahmin	Finansal bilgi manipülasyonu yapmayan (0)	Finansal bilgi manipülasyonu yapan (1)	Toplam
Finansal bilgi manipülasyonu yapmayan (0)	100	0	100
Finansal bilgi manipülasyonu yapan (1)	21	0	21
Toplam	121	0	121

Test seti için doğru sınıflandırma yüzdesi 82.64463 olarak bulunmuştur. Hatalı sınıflandırma yüzdesi ise 17.355371'dir.

Eđitim, geerlilik ve test setleri iin elde edilen sonular birleřtirildiđinde yapay sinir ađı uygulamasına gre Tablo 5 elde edilmiř olur.

Tablo 5. Modelin Yapay Sinir Ađı Uygulamasına Gre Sınıflandırması
(10-4-1)

Gerek / Tahmin	Finansal bilgi maniplasyonu yapmayan (0)	Finansal bilgi maniplasyonu yapan (1)	Toplam
Finansal bilgi maniplasyonu yapmayan (0)	1039	1	1040
Finansal bilgi maniplasyonu yapan (1)	166	2	168
Toplam	1205	3	1208

Yapay sinir ađı uygulamasına gre elde edilen genel dođruluk yzdesi 86.175496 olarak bulunmuřtur. Hatalı sınıflandırma yzdesi ise 13.824503'tr.

Modele eklenecek yeni bir řirketin gelecekteki durumu tahmin edilmek istendiđinde yapay sinir ađı uygulamasına gre tahminin dođru olma olasılıđı % 86.175496 olmaktadır.

3.3.2. Altı Gizli Katmanlı Modelin Sonuları

Tablo 6. Modelin Eđitim Seti iin Sınıflandırması
(10-6-1)

Gerek / Tahmin	Finansal bilgi maniplasyonu yapmayan (0)	Finansal bilgi maniplasyonu yapan (1)	Toplam
Finansal bilgi maniplasyonu yapmayan (0)	832	0	832
Finansal bilgi maniplasyonu yapan (1)	134	0	134
Toplam	966	0	966

Eđitim seti iin dođru sınıflandırma yzdesi 86.128365 olarak bulunmuřtur. Hatalı sınıflandırma yzdesi ise 13.871635'tir.

Tablo 7. Modelin Geçerlilik Seti İçin Sınıflandırması
(10-6-1)

Gerçek \ Tahmin	Finansal bilgi manipülasyonu yapmayan (0)	Finansal bilgi manipülasyonu yapan (1)	Toplam
Finansal bilgi manipülasyonu yapmayan (0)	108	0	108
Finansal bilgi manipülasyonu yapan (1)	13	0	13
Toplam	121	0	121

Geçerlilik seti için doğru sınıflandırma yüzdesi 89.256195 olarak bulunmuştur. Hatalı sınıflandırma yüzdesi ise 10.743802'dir.

Tablo 8. Modelin Test Seti İçin Sınıflandırması
(10-6-1)

Gerçek \ Tahmin	Finansal bilgi manipülasyonu yapmayan (0)	Finansal bilgi manipülasyonu yapan (1)	Toplam
Finansal bilgi manipülasyonu yapmayan (0)	100	0	100
Finansal bilgi manipülasyonu yapan (1)	21	0	21
Toplam	121	0	121

Test seti için doğru sınıflandırma yüzdesi 82.64463 olarak bulunmuştur. Hatalı sınıflandırma yüzdesi ise 17.355371'dir.

Eğitim, geçerlilik ve test setleri için elde edilen sonuçlar birleştirildiğinde yapay sinir ağı uygulamasına göre Tablo 9 elde edilmiş olur.

Tablo 9. Modelin Yapay Sinir Ağı Uygulamasına Göre Sınıflandırması
(10-6-1)

Gerçek \ Tahmin	Finansal bilgi manipülasyonu yapmayan (0)	Finansal bilgi manipülasyonu yapan (1)	Toplam
Finansal bilgi manipülasyonu yapmayan (0)	1040	0	1040
Finansal bilgi manipülasyonu yapan (1)	168	0	168
Toplam	1208	0	1208

Yapay sinir ağı uygulamasına göre elde edilen genel doğruluk yüzdesi 86.092715 olarak bulunmuştur. Hatalı sınıflandırma yüzdesi ise 13.907284'tür.

Modele eklenecek yeni bir şirketin gelecekteki durumu tahmin edilmek istendiğinde yapay sinir ağı uygulamasına göre tahminin doğru olma olasılığı % 86.092715 olmaktadır.

4 gizli katmanlı model (10-4-1) ile 6 gizli katmanlı modelin (10-6-1) sonuçları Tablo 10'da özetlenmiştir.

Tablo10. Dört Gizli Katmanlı Model ile Altı Gizli Katmanlı Yapay Sinir Ağı Modelleri

10-4-1 (Genel Doğruluk %)	10-6-1(Genel Doğruluk %)
86.175496	86.092715
10-4-1 (Hatalı sınıflandırma %)	10-6-1(Hatalı sınıflandırma %)
13.824503	13.907284

Bu durumda 4 gizli katmanlı modelin tahmin gücü (% 86.175496) 6 gizli katmanlı modelin tahmin gücünden (% 86.092715) daha yüksek bulunduğundan, yine 4 gizli katmanlı modelin hatalı sınıflandırma yüzdesi (%13.824503), 6 gizli katmanlı modelin hatalı sınıflandırma yüzdesinden (%13.907284) daha düşük olduğundan dolayı 4 gizli katmanlı olan model yapay sinir ağı modeli olarak seçilmiştir.

4. SONUÇ

Literatüre sunulan modellerde, açıklama güçlerine göre finansal bilgi manipülasyonuna başvuran ve başvurmeyen şirket ayırımına gidilerek, manipüle edilmiş finansal bilgi ortaya çıkarılmaya çalışılmaktadır.

Bu çerçevede, Küçüksözen ve Küçükkocaoğlu (2005) tarafından Beneish Modeli'ni örnek alan ve çalışmamızda yer alan veri setini kullanan probit modelin bulguları, İMKB'de işlem gören 126 şirketin her biri için, 1997 yılı verilerini kullanarak ulaşılan denklemin, 1993-2002 dönemindeki yıllara ilişkin bağımsız değişken değerlerinin hesaplanıp, bu değişken değerlerin denkleminde yerlerine konularak, her bir şirket için finansal bilgi manipülasyonu olasılığını tahmin etme yönündedir. Nitekim, probit model çerçevesinde yapılan hesaplama sonuçlarına göre Küçüksözen ve Küçükkocaoğlu (2005), finansal bilgi manipülatörü şirketleri (% 33-57 aralığında) ortalama % 38 oranında, manipülatör olmayan (kontrol) şirketleri de (% 43-74 aralığında) ortalama % 61 oranında doğru tahmin etmişlerdir. Bu oranlar, özellikle manipülatör şirketler açısından Beneish'in (1999) çalışmasında ortaya çıkan oranlara yakındır⁵.

Bu çalışmada ise, finansal bilgi manipülasyonu yapan ve yapmayan şirketlerin ayırımı yapay sinir ağı modeli ile tahmin edilmeye çalışılmıştır. Bulgularımız, çalışmada elde edilen sonuçlara göre, tahminin doğru olma olasılığının %86.17 düzeyinde gerçekleştiğini, hatalı sınıflandırma olasılığının ise %13.82 olabileceğini göstermektedir. Her ne kadar, probit model bulgularıyla bire bir karşılaştırma yapma imkânımız olmasa da, yapay sinir ağı modelinin, yüksek oranlarda doğru sınıflandırma yaptığını, böylece gelecekte finansal bilgi manipülasyonuna başvuran şirketleri tahmin ederken bu modelin de göz önünde bulundurulması gerektiğini düşünmekteyiz.

⁵ Beneish'in (1999) modeli, manipülatör şirketleri % 37,5-56,1 aralığında manipülatör olarak tahmin etmektedir. Bu oranlar, kontrol şirketleri için % 80-92 aralığındadır.

Sonu olarak, finansal bilgi manipölasyonunu ortaya ıkarmaya yarayan deęişkenler bilindięinde, modele yeni katılan Őirketlerin gelecekteki durumlarını tahmin etmek için yapay sinir aęları yaklaşımı bir yöntem olarak kullanılabilir.

KAYNAKLAR

- Beneish, M. D., (1997), "Detecting GAAP Violation: Implications for Assessing Earnings Management Among Firms with Extreme Financial Performance", *Journal of Accounting and Public Policy*, Vol:16, No: 3, pp: 271-309.
- Beneish, M. D., (1999), "The Detection of Earnings Manipulation", *Financial Analysts Journal*, Vol:55, No:5, pp:24-36.
- DeAngelo, L.E. (1986), "Accounting Numbers as Market Valuation Substitutes: A Study of Management Buyouts of Public Stockholders", *The Accounting Review*, Vol:61, No:3, pp. 400-420.
- Dechow, P.M., Sloan, R.G., Sweeney, A.P., (1995), "Detecting Earnings Management", *The Accounting Review*, Vol:70, No:2, pp: 193-225.
- Healy, P.M., (1985), "The Effect of Bonus Schemes on Accounting Decisions," *Journal of Accounting and Economics*, Vol:7, pp:85-107.
- Fanning K, Cogger KO, Srivastava R. (1995), "Detection of management fraud: A neural network approach", *Intelligent Systems in Accounting, Finance and Management*, 4: No. 2, pp:113–126.
- Fanning K, Cogger KO, (1998), "Neural Network Detection of Management Fraud Using Published Financial Data", *Intelligent Systems in Accounting, Finance and Management*, 7, pp:21–41
- Gülseçen, S. (1995). "Yapay Sinir Ağları ile Finansal Uygulamalar ve Döviz Kuru Tahmini İçin Bir Öneri", 4.Türk Yapay Zeka ve Yapay Sinir Ağları Sempozyumu Bildirileri, 26-28 Haziran. (TAINN'95), pp:51-61.
- Güneri, N. (2001). Öğrenci Başarısızlıklarının Analizinde Sinir Ağları Yaklaşımının Lojistik Regresyon Analizi İle Karşılaştırılması, (Yayınlanmamış Yüksek Lisans Tezi), Ankara: Ankara Üniversitesi.
- Hecht-Neilsen, R. (1989). *Neurocomputing*, Massachusetts, Addison-Wesley Pub. Comp.
- Jones, J., (1991), "Earnings management during import relief investigations", *Journal of Accounting Research*, Vol: 29, No:2, pp:193-228.
- Koh, H.C., Tan, S.S. (1999), "A Neural Network Approach to the Prediction of Going Concern Status", *Accounting and Business Research*, Vol: XXIX, No:3, pp: 211-216.
- Küçükkocaoğlu, G., Küçüksözen, C., (2005), "Gerçeğe Aykırı Finansal Tabloların Ortaya Çıkarılması: İMKB Şirketleri Üzerine Ampirik Bir Çalışma", *Muhasebe ve Finansman Dergisi*, Sayı 28.

- Küçüksözen, C., (2005), “Finansal Bilgi Manipülasyonu: Nedenleri, Yöntemleri, Amaçları, Teknikleri, Sonuçları Ve İMKB Şirketleri Üzerine Ampirik Bir Çalışma”, SPK Yayınları, No.183, Temmuz 2005, Ankara.
- Küçüksözen, C., Küçükkocaoğlu, K., (2005), “Finansal Bilgi Manipülasyonu: İMKB Şirketleri Üzerine Ampirik Bir Çalışma”, "1st International Accounting Conference On The Way To Convergence" Kasım 2004, İstanbul, Muhasebe Bilim Dünyası (Möдав) Bildiri Kitabı.
- Salchenberger, L.M., Çınar, M., Lash, N.A. (1992). “Neural Networks: A New Tool for Predicting Thrift Failure”, Decision Sciences, Vol: XXIII, No: 4, pp: 899-916.
- Spathis, C., (2002), “Detecting False Financial Statements Using Published Data: Some Evidence From Greece”, Managerial Auditing Journal, Vol: 17, No: 4, pp: 179-191.
- Spathis, C., Doumpou M., Zopounidis, C., (2004), “Detecting falsified financial statements: a comparative study using multicriteria analysis and multivariate statistical techniques”, The European Accounting Review, Vol: 11, No: 3, pp: 509–535
- Sungur, M. (Ed.) (1995). Mühendis Gözüyle Yapay Sinir Ağları, Ankara, ODTÜ.
- Wilson, N., Chong, K.S. (1995). “Neural Network Simulation and Prediction of Corporate Outcomes: Some Empirical Findings”, International Journal of the Economics of Business, Vol: II, No: 2, pp: 31-51.
- Yıldız, B. (2001). “Finansal Başarısızlığın Öngörülmesinde Yapay Sinir Ağı Kullanımı ve Halka Açık Şirketlerde Ampirik Bir Uygulama”, İstanbul Menkul Kıymetler Borsası Dergisi, Vol:17, pp : 51-67.

Ek.

Ampirik çalışmamız için belirlenen 10 bağımsız değişkenin hesaplanma yöntemi ve modeldeki fonksiyonları aşağıda açıklanmaktadır⁶.

Satışlardaki Büyüme Endeksi

$$(SBE) = \frac{Brüt\ Satışlar_t}{Brüt\ Satışlar_{t-1}}$$

şeklinde hesaplanmaktadır. Satışlardaki büyüme başlı başına finansal bilgi manipülasyonu yapıldığını göstermemektedir. Bununla birlikte büyüyen şirketler, profesyoneller tarafından diğer şirketlere göre finansal bilgi manipülasyonuna daha çok yatkın olarak görülmektedir. Çünkü bu şirketlerde, borç öz kaynak yapıları ve kaynak ihtiyaçları yöneticiler üzerinde satışları artırmak yönünde büyük bir baskı oluşturmaktadır. Eğer bu tür şirketlerde, büyümedeki yavaşlamaya bağlı olarak hisse senedi fiyatlarında bir düşüş gözlenirse, bu durumda şirket yöneticileri açısından finansal bilgi manipülasyonu yapma yönünde daha büyük bir baskı oluşmaktadır.

Ticari Alacaklar Endeksi

$$(TAE) = \frac{Ticari\ Alacaklar_t / Brüt\ Satışlar_t}{Ticari\ Alacaklar_{t-1} / Brüt\ Satışlar_{t-1}}$$

şeklinde hesaplanmıştır. Bu endeks satışlara göre şirketin ticari alacaklarında t-1 yılına göre t yılında meydana gelen değişimi göstermektedir. Şirketin kredili satış politikasında çok önemli bir değişiklik olmadığı sürece bu endeksin doğrusal bir trend izlemesi beklenir. Bu endekste önemli bir artış; şirketin gelirlerinin, dolayısıyla karının artırılmasına yönelik, konsinye satışların ticari alacak ve satışlar şeklinde muhasebeleştirilmesi ya da grup içi şirketlerin cari hesapları üzerinden ticari alacak oluşturmak suretiyle gerçekleştirilebilecek finansal bilgi manipülasyonu uygulamalarının bir göstergesi olarak değerlendirilmektedir.

Brüt Kar Marjı Endeksi

$$(BKM) = \frac{(Brüt\ Satışlar_{t-1} - Satılan\ Mal\ Maliyeti_{t-1}) / Brüt\ Satışlar_{t-1}}{(Brüt\ Satışlar_t - Satılan\ Mal\ Maliyeti_t) / Brüt\ Satışlar_t}$$

şeklinde hesaplanmaktadır. Endeksin 1'den büyük olması şirketin brüt kar marjının kötüleşmekte olduğunu göstermektedir. Bu durum şirketin geleceğe ilişkin beklentisinde bir olumsuzluk olarak algılanmaktadır. Bu durumda olan şirketlerin brüt kar marjını düzeltmek üzere, satış gelirlerinde artış ya da satış maliyetlerinde azalış izlenimi (ya da her ikisini birden) yaratmak amacıyla finansal bilgi manipülasyonuna başvuracakları kabul edilmektedir.

⁶ Ampirik çalışmamız için belirlenen 10 bağımsız değişken ve değişkenlere ait veri seti ve açıklamalar, Küçüksözen (2005) ve Küçüksözen ve Küçükkocaoğlu'nun (2005) çalışmalarından alınmıştır.

Aktif Kalitesi Endeksi

$$(AKE) = \frac{(1 - \text{Dönen Varlıklar}_t + \text{Maddi Duran Varlıklar}_t) / \text{Toplam Varlıklar}_t}{(1 - \text{Dönen Varlıklar}_{t-1} + \text{Maddi Duran Varlıklar}_{t-1}) / \text{Toplam Varlıklar}_{t-1}}$$

şeklinde hesaplanmaktadır. Endeks, toplam varlıkların içinde, dönen varlıklar ve maddi duran varlıklar (makine, tesis ve teçhizat) dışında kalan diğer duran varlıklarda bir önceki yıla göre meydana gelen değişimi göstermektedir. Bu endeksin 1'den yüksek olması, şirketin giderlerini cari dönem gideri olarak gelir tablosuna yansıtması yerine aktifleştirdiğine ve böylece finansal bilgi manipülasyonu yaptığına işaret etmektedir. Dolayısıyla, aktif kalitesi endeksi ile finansal bilgi manipülasyonu olasılığı arasında pozitif bir korelasyon beklenmektedir.

Amortisman Endeksi

$$(AME) = \frac{\Delta B. Amortismanlar_{t-1} / (\Delta B. Amortismanlar_{t-1} + \text{Maddi Duran Varlıklar}_{t-1})}{\Delta B. Amortismanlar_t / (\Delta B. Amortismanlar_t + \text{Maddi Duran Varlıklar}_t)}$$

şeklinde hesaplanmaktadır. Çalışmamızda, amortisman giderleri bilanço ya da gelir tablosu kalemlerinden doğrudan hesaplanmadığı için, herhangi bir dönemin amortisman gideri; o dönemin birikmiş amortisman tutarı ile bir önceki dönemin birikmiş amortisman tutarı arasındaki fark olarak belirlenmiştir. Bu tutar ilgili dönemin amortisman gideri ile farklılık arz edebilir. Zira amortisman tabi varlıklarda o dönemde meydana gelen değişim, amortisman giderini çok fazla etkilemeden birikmiş amortisman tutarını değiştirebilecektir. Bununla birlikte aşağıda değinildiği üzere, çalışma kapsamındaki şirketlerin reel sektörde faaliyet gösteren şirketler olduğu, dolayısıyla amortisman tabi varlıklarında çok fazla değişim olmadığı dikkate alınarak, amortisman giderlerinin bu şekilde hesaplanmasının doğru bir yaklaşım olacağı düşünülmektedir.

Bu oranın 1'den büyük olması şirketin karı yüksek göstermek üzere amortisman giderlerini (maddi duran varlıkların kullanım ömrüne ilişkin tahmini süreyi daha uzun olarak kayıtlara yansıtması ya da amortisman metodunu gideri azaltacak şekilde değiştirmek suretiyle) azaltmış olabileceğine işaret etmektedir.

Diğer taraftan, çalışmamızda analiz kapsamına alınan şirketler reel sektörde faaliyet gösteren imalat sanayi şirketleri olduğundan, bu endekste yıllar itibarıyla pek bir değişiklik olmaması beklenir. Zira imalat sanayinde faaliyet gösteren şirketlerin amortisman tabi varlıklarında çok fazla hareket olması (alım-satım yapılması) beklenmez. Bu husus da dikkate alındığında, bu endekste yıllara göre önemli artışlar olması, amortisman giderleri üzerinde finansal bilgi manipülasyonu olarak değerlendirilebilecek işlemler yapıldığı şeklinde yorumlanmaktadır. Bu nedenle modelimizde amortisman giderleri endeksi ile finansal bilgi manipülasyonu olasılığı arasında pozitif bir ilişki olduğu kabul edilmiştir.

Pazarlama, Satış, Dağıtım ve Genel Yönetim Giderleri Endeksi

$$(PSE) = \frac{(Pazarlama, Satış ve Dağıtım Giderleri + Genel Yönetim Giderleri) / Brüt Satışlar_t}{(Pazarlama, Satış ve Dağıtım Satış Giderleri + Genel Yönetim Giderleri) / Brüt Satışlar_{t-1}}$$

şeklinde hesaplanmaktadır. Pazarlama, satış, dağıtım ve genel yönetim giderleri ile satışlar arasında, uzun dönemde pek değişmemesi gereken bir ilişki olması beklenir. Zira bu giderler şirketlerin esas faaliyetlerinin sonucuna, diğer bir ifade ile satışlara bağlı olarak değişen değişken giderler niteliğindedir. Dolayısıyla bu değişkende önemli değişimler olması, diğer bir ifade ile satışlarla bu giderler arasındaki oransal ilişkide önemli bir düşüş görülmesi, verimlilikte önemli bir artış olmadığı sürece, satışların manipüle edildiği ya da giderlerin eksik kaydedildiği şeklinde değerlendirilebilir. Bu çerçevede bu endeksle finansal bilgi manipülasyonu olasılığı arasında pozitif bir ilişki olduğu düşünülmektedir.

Kaynak Yapısındaki Değişim Endeksi

$$(KYE) = \frac{(Uzun Vadeli Borçlar + Kısa Vadeli Borçlar) / Toplam Varlıklar_t}{(Uzun Vadeli Borçlar + Kısa Vadeli Borçlar) / Toplam Varlıklar_{t-1}}$$

şeklinde hesaplanmaktadır. Bu değişkenin 1'den büyük olması şirketin borçluluk oranının arttığını göstermektedir. Modelde bu değişkene yer verilmesinin nedeni borçlanma koşullarını yerine getirememe durumundan kaçınmak amacıyla yapılacak finansal bilgi manipülasyonu uygulamalarını ortaya çıkarmaya yöneliktir.

Toplam Tahakkukların Toplam Varlıklara Oranı

$$(TVE) = \frac{\Delta \text{Dönen Varlıklar} - \Delta \text{Hazır Değerler} - (\Delta \text{Kısa Vadeli Borçlar} - \Delta \text{Uzun Vadeli Borç Anapara Taksit ve Faizleri} - \Delta \text{Ödenecek Vergi ve Diğer Yasal Yükümlülük Karşılığı}) - \text{Amortisman Giderleri}}{\text{Toplam Varlıklar}_t}$$

şeklinde hesaplanmaktadır. Bu şekilde hesaplanan TVE, tahakkuk esas çerçevesinde (şirket yönetiminin inisiyatifi ile) oluşturulan borç-alacak ile gelir-gider kalemlerinde meydana gelen değişimi göstermektedir. Bu değişkenin modele dahil edilmesinin nedeni, şirket yönetiminin tahakkuk esas çerçevesinde gelirleri artırmak ya da giderleri azaltmak (ya da tersi) suretiyle finansal bilgi manipülasyonu uygulamasına gidip gitmediğini ortaya koymaktır. Dolayısıyla bu değişkende, diğer bir ifade ile nakit dışı işletme sermayesinde meydana gelen yüksek düzeydeki bir artış ya da azalış, olası bir finansal bilgi manipülasyonuna işaret etmektedir.

Stokların Brüt Satışlara Oranı

$$(SSE) = \frac{\text{Stoklar}_t / \text{Brüt Satışlar}_t}{\text{Stoklar}_{t-1} / \text{Brüt Satışlar}_{t-1}}$$

şeklinde hesaplanmaktadır. Şirket yönetimleri karı düşük ya da yüksek gösterme amaçlarına bağlı olarak genel üretim giderlerini satılan malın maliyeti ya da stoklara değişik oran ya da ölçüde yansıtılabilmekte ya da stok değerlendirme yöntemlerini (LIFO, FIFO ve Ortalama Maliyet) değiştirebilmektedirler.

Finansman Giderlerinin Brüt Satışlara Oranı

$$(FSE) = \frac{\text{Finansman Giderleri}_t / \text{Brüt Satışlar}_t}{\text{Finansman Giderleri}_{t-1} / \text{Brüt Satışlar}_{t-1}}$$

şeklinde hesaplanmaktadır. Türkiye’de ortaya çıkarılan finansal bilgi manipülasyonu uygulamalarında en sık karşılaşılan durumlardan biri finansman giderlerinin cari dönem gideri olarak gelir tablosuna yansıtılması yerine alıcılar, stoklar, gelecek yıllara ait giderler, iştirakler, maddi duran varlıklar, maddi olmayan duran varlıklar ve/veya yapılmakta olan yatırımlar hesaplarına eklenerek aktifleştirilmesidir. Dolayısıyla şirket yönetimleri çeşitli amaçlarla dönem karını artırmak (azaltmak) istediklerinde cari dönem finansman giderlerinin önemli bir kısmını aktifleştirecek (dönem gideri olarak kaydedecek), böylece istedikleri sonucu sağlayabileceklerdir. Vergi mevzuatının finansman giderlerinin dönem gideri olarak kaydedilmesi ya da aktifleştirilmesi konusunda esnek bir yapıya sahip olması, bu tür finansal bilgi manipülasyonu uygulamalarının yaygın olarak ortaya çıkmasına katkıda bulunmaktadır. Bu çerçevede bu değişkenle finansal bilgi manipülasyonu arasında bir ilişki olduğu varsayılmıştır.