

162354

T.C.  
DOKUZ EYLÜL ÜNİVERSİTESİ  
SOSYAL BİLİMLER ENSTİTÜSÜ  
İŞLETME ANABİLİM DALI  
SAYISAL YÖNTEMLER VE YÖNETİM BİLİMİ PROGRAMI  
YÜKSEK LİSANS TEZİ

**HALKA ARZLARIN İLK GÜN FİYAT  
PERFORMANSLARININ TAHMİNİNDE YAPAY SİNİR  
AĞLARININ KULLANIMI**

**Aysun KAPUCUGİL**

Tez Danışmanı  
**Yrd. Doç. Dr. Yılmaz GÖKŞEN**

2005

## YEMİN METNİ

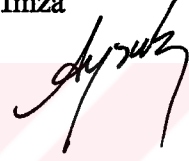
Yüksek Lisans/~~Doktora~~ tezi olarak sunduğum “Halka Arzların İlk Gün Fiyat Performanslarının Tahmininde Yapay Sinir Ağlarının Kullanımı” adlı çalışmanın, tarafımdan, bilimsel ahlak ve geleneklere aykırı düşecek bir yardıma başvurmaksızın yazıldığını ve yararlandığım eserlerin bibliyografyada gösterilenlerden oluştuğunu, bunlara atıf yapılarak yararlanılmış olduğunu belirtir ve bunu onurumla doğrularım.

Tarih

06/07/2005

Adı SOYADI:

İmza



## TUTANAK

Dokuz Eylül Üniversitesi Sosyal Bilimler Enstitüsü' nün ...../..../2005 tarih ve .....sayılı toplantısında oluşturulan jüri, Lisansüstü Öğretim Yönetmeliği'nin .....maddesine göre İşletme Anabilim/ ~~Anasana~~ Dalı yüksek lisans/~~doğtora~~ öğrencisi Aysun KAPUCUGİL' in "Halka Arzların İlk Gün Fiyat Performanslarının Tahmininde Yapay Sinir Ağlarının Kullanımı" konulu tezi incelenmiş ve aday ~~27.10.77~~ 27.10.77 2005 tarihinde, saat ~~9.30~~ 9.30 da jüri önünde tez savunmasına alınmıştır.

Adayın kişisel çalışmaya dayanan tezini savunmasından sonra ~~9.10~~ 9.10 dakikalık süre içinde gerek tez konusu, gerekse tezin dayanağı olan anabilim dallarından jüri üyelerine sorulan sorulara verdiği cevaplar değerlendirilerek tezin başarılı.....olduğuna oy birliği.....ile karar verildi.

BAŞKAN

Prof. Dr. Sevilner Gönüşler

ÜYE

Yrd. Doç. Dr. Yılmaz Gözler  
Gözler

ÜYE

Doç. DR. M. BANLI DURUKAN

# YÜKSEKÖĞRETİM KURULU DOKÜMANTASYON MERKEZİ TEZ VERİ FORMU

Tez No: Konu Kodu: Üniv. Kodu

Not: Bu bölüm merkezimiz tarafından doldurulacaktır.

Tez Yazarının

Soyadı: Kapucugil

Adı: Aysun

Tezin Türkçe Adı: Halka Arzların İlk Gün Fiyat Performanslarının Tahmininde Yapay Sinir Ağlarının Kullanımı

Tezin Yabancı Dildeki Adı: Using Artificial Neural Networks to Predict Post-Issue Market Price Performance of Initial Public Offerings

Tezin Yapıldığı

Üniversite: Dokuz Eylül Üniversitesi

Enstitü: Sosyal Bilimler

Yıl: 2005

Diğer Kuruluşlar:

Tezin Türü:

Yüksek Lisans:

Dili: Türkçe

Doktora:

Sayfa Sayısı: 155

Tıpta Uzmanlık:

Referans Sayısı: 81

Sanatta Yeterlilik:

Tez Danışmanlarının

Ünvanı: Yrd. Doç. Dr.

Adı: Yılmaz

Soyadı: Gökşen

Türkçe Anahtar Kelimeler:

1- Yapay Sinir Ağları

2- Yapay Zeka

3- Finans

4- İlk Halka Arz

5- Düşük Fiyatlama

İngilizce Anahtar Kelimeler:

1- Artificial Neural Networks

2- Artificial Intelligence

3- Finance

4- Initial Public Offering

5- Underpricing

Tarih: 06/07/2005

İmza:

Tezimin Erişim Sayfasında Yayınlanmasını İstiyorum

Evet

Hayır

## ÖNSÖZ

Tez çalışmalarım süresince bilgi ve deneyimleri ile beni yönlendiren ve en yoğun zamanlarımda tolerans sınırlarını sonuna kadar kullanan sayın hocam Yrd. Doç. Dr. Yılmaz GÖKŞEN'e saygılarımla teşekkürlerimi sunuyorum.

Tez aşaması boyunca en az danışman hocam kadar desteklerini esirgemeyen, bilgi ve deneyimlerini her zaman benimle paylaşan Prof. Dr. Şevkinaz GÜMÜŞOĞLU'na, Doç. Dr. M. Banu DURUKAN'a ve Öğr. Gör. Sabri ERDEM'e teşekkürlerimi sunuyorum.

Tezin uygulaması sırasında piyasa deneyimlerini aktaran ve verilerin toplanması sırasında ilgili insanlarla bağlantı kurmamı sağlayan sayın Aydın EROĞLU'na teşekkür ediyorum.

Tezimi yazarken sürekli yanımda olan ve bu süreci elinden geldiğince kolaylaştırmaya çalışan Erdem İKİZ'e çok teşekkür ediyorum.

Çalışma arkadaşlarım Arş. Gör. Gülüzar KURT'a, Arş.Gör. Güzin ÖZDAĞOĞLU ve Aşkın ÖZDAĞOĞLU'na çok teşekkürler...

Son olarak, her zaman her türlü destekleri ile yanımda olan sevgili AİLEME sonsuz teşekkürler...

Aysun KAPUCUGİL

Temmuz, 2005

## ÖZET

Finansal konularda verilen kararların kalitesini artırmak için geliştirilen yapay sinir ağları teknolojisi, gürültülü veya eksik veriler karşısında bile makul sonuçlar üretebilmekte ve doğrusal olmayan ilişkileri başarılı bir şekilde modelleyebilmektedir. Bu teknoloji özellikle, gürültülü ya da eksik verilere sahip olan ve doğrusal ilişkilerden ziyade doğrusal olmayan ilişkileri bünyesinde barındıran finansal problemlerin çözümünde uygun bir araç durumundadır.

Finansal alandaki en önemli problemlerden biri de ilk halka arzların fiyatlanmasıdır. Bu süreç, oldukça karmaşık ve çok farklı boyutların etkisinde kalan bir süreçtir. Süreçte kilit rollere sahip olan, hisselerini ihraç eden şirket, aracı kurum ve yatırımcı olmak üzere üç taraf bulunmaktadır. Bu üç tarafın amaçları birbirinden farklıdır ve her biri karını maksimize etmeye çalışmaktadır. İlk halka arzlarda, bu üç tarafın çıkarlarını dengeleyecek ilk halka arz fiyatının ne olacağına ilişkin karar verilmesi gerekmektedir. Bu süreçte önemli olan, hisse senedinin piyasada işlem görmeye başladıktan sonraki piyasa değerinin doğru tahmin edilmesi ve bu değere yakın ilk halka arz fiyatlamalarının yapılabilmesidir. Hisse senedinin piyasaya çıktıktan sonraki fiyatı, ilk kez halka arz edilen hisse senedinin, piyasadaki ilk işlem gününün sonunda ulaştığı kapanış değeridir.

Bu çalışmanın kapsamında, yapay sinir ağlarının bir tahminleme aracı olarak kullanımı incelenip analiz edilmiştir. Spesifik olarak, yapay sinir ağlarının ilk halka arzların piyasa değerlerini tahmin etme performansları incelenmiş ve ağın ürettiği fiyatlarla klasik tahminleme yöntemi olan çoklu regresyon tekniği ile elde edilen fiyatlar karşılaştırılmıştır. Son olarak, koşullu olasılıklar kullanılarak yapay sinir ağı modelinin tahminin doğruluk derecesi hesaplanmıştır.

**Bu çalışmada, biri 50 milyon \$'ın üzerinde toplam varlığa sahip olan büyük firmalar diğeri ise 50 milyon \$'ın altında toplam varlığa sahip olan küçük firmalar için olmak üzere iki yapay sinir ağı modeli geliştirilmiştir. Birinci modelin düşük fiyatlanmış ilk halka arzları doğru tahmin etme olasılığı yüzde 61.54 iken, çoklu regresyon aynı veri seti için bu olasılığı yüzde 7.69'dir. İkinci modelde aynı olasılık değerleri her iki model için sırasıyla yüzde 90 ve yüzde 40 olarak bulunmuştur.**

**Burada, yapay sinir ağlarının ilk halka arzların piyasa çıktıktan sonraki fiyatlarını tahmin edebilecek yetenekte olduğu ve iyi eğitildiği takdirde, karar vericiler için faydalı bir tahminleme aracı olarak kullanılabileceği sonucu elde edilmiştir.**

## **ABSTRACT**

**There has been considerable interest in the development of artificial neural networks for improving the quality of decisions in financial applications. Neural network technology is known for its ability to respond reasonably even when augmented with noisy or incomplete data and existed nonlinear relationships between data. These characteristics of the neural network technology are reasons of being preferable problem solving tool in finance, for financial data are often noisy or incomplete and have inherently nonlinear structure rather than linearity.**

**One of the most important problems in financial world is the pricing of Initial Public Offerings (IPO). This process has been considerable complex and also affected from several variables that are independent and have unclear relationships with each other. In this process, there are three key players which are the issuing firm, the underwriter, and the investor. The objectives of them differ from one another and each tries to maximize his profit. Eventually, determining an IPO price which would balance the interests of these three players is the decision point in this process. Thus, the important task here is to forecast the post-issue market price with high accuracy and then to price IPO as possible as close to its market price. Post issue market price is the price of an IPO stock at end of the first day of trading on the market.**

**This research examines and analyzes the use of artificial neural networks as a forecasting tool. Specifically a neural network's ability to predict post-issue market prices of IPOs is tested. Accuracy is compared against a traditional forecasting method, multiple linear regression analysis. Finally, the probability of the model's forecast being correct is calculated using conditional probabilities.**



**This research describes the development of two neural networks, one is developed for the big firms having total assets greater than 50 million USD and the other is developed for the small firms having total assets less than 50 million USD . First neural network model achieved a 61.54 percent probability of predicting IPO underpricing while the multiple regression model was achieving 7.69 percent for this probability. The neural network model and the multiple regression model which are developed for the second case, performed 90 percent probability and 40 percent probability, respectively.**


**It was concluded that neural networks do have the capability to forecast post-issue market prices of Initial Public Offerings and, if properly trained, the decision makers could benefit from the use of this forecasting tool.**



## İÇİNDEKİLER

YEMİN METNİ .....	ii
TUTANAK.....	iii
YÜKSEKÖĞRETİM KURULU DOKÜMANTASYON MERKEZİ TEZ VERİ FORMU.....	iv
ÖNSÖZ .....	v
ÖZET .....	vi
ABSTRACT .....	viii
İÇİNDEKİLER.....	x
TABLolar LİSTESİ.....	xii
ŞEKİLLER LİSTESİ.....	xiii
EKLER LİSTESİ.....	xiv
GİRİŞ .....	xv
1 ÇALIŞMANIN AMACI, KAPSAMI VE YÖNTEMİ.....	1
1.1 Çalışmanın Amacı ve Yazına Katkısı.....	1
1.2 Araştırma Soruları .....	2
1.3 Çalışmanın Kapsamı, Sınırlamaları ve Varsayımları .....	2
1.4 Araştırmanın Yöntemi .....	3
2 YAPAY SINİR AĞLARI.....	4
2.1 Yapay Sinir Ağlarının Gelişim Kronolojisi .....	5
2.2 Yapay Sinir Ağlarının Biyolojik Temeli .....	6
2.3 Yapay Sinir Ağlarının Temel Yapısı.....	9
2.3.1 Yapay Sinir Ağlarının Bileşenleri .....	9
2.3.2 Yapay Sinir Ağlarının İşleyişi.....	11
2.3.3 Yapay Sinir Ağlarında Öğrenme .....	16
2.3.4 Yapay Sinir Ağlarının Eğitimi ve Testi .....	20
2.3.5 Yapay Sinir Ağlarının Öğrenme Algoritmaları.....	24
2.3.6 Yapay Sinir Ağlarının Mimari Yapısı .....	32
2.4 Yapay Sinir Ağları Teknolojisinin Değerlendirilmesi .....	37
2.4.1 Yapay Sinir Ağlarının Güçlü Yanları .....	37
2.4.2 Yapay Sinir Ağlarının Zayıf Yönleri .....	40
3 İLK HALKA ARZLAR .....	42
3.1 Giriş .....	42
3.2 Türkiye’de Halka Açılma .....	44
3.3 Şirketler Neden Halka Açılır?.....	47
3.4 Halka Açılma Süreci.....	50
3.5 Türkiye’de Halka Arza Aracılık Faaliyeti .....	53
3.6 Halka İlk Arzlarda Hisse Senetlerinin Düşük Fiyatlanması .....	56
3.6.1 Asimetrik Bilgi Modelleri .....	57
3.6.2 Kurumsal Nedenler .....	59
3.6.3 Sahiplik ve Kontrol.....	60
3.6.4 Davranışsal Açıklamalar .....	61
4 YAPAY SINİR AĞI MODELİNİN TASARIMI .....	62
4.1 Yöntem .....	62
4.1.1 Örneklerin Toplanması .....	63
4.1.2 Veri Analizi .....	65
4.1.3 Yapay Sinir Ağı Modelinin Geliştirilmesi .....	69

4.2	Yapay Sinir Ağı Modelinin Eğitilmesi ve Test Edilmesi .....	73
4.2.1	Ağın Eğitimi .....	73
4.2.2	Ağın Test Edilmesi .....	74
5	PERFORMANS DEĞERLENDİRME .....	75
5.1	Performans Değerlendirme Ölçütleri .....	75
5.1.1	Çoklu Regresyon .....	76
5.1.2	Koşullu Olasılıklar .....	80
5.2	YSA Modelinin A Seti (N=104) Üzerindeki Performansı .....	81
5.2.1	Çoklu Regresyon Sonuçları.....	86
5.2.2	Koşullu Olasılıkların Hesaplanması .....	90
5.3	YSA Modelinin B Seti (N=61) Üzerindeki Performansı.....	92
5.3.1	Çoklu Regresyon Sonuçları.....	96
5.3.2	Koşullu Olasılıkların Hesaplanması .....	100
	SONUÇ VE DEĞERLENDİRME .....	102
	KAYNAKLAR.....	107
	BİBLİYOGRAFI.....	116
	EKLER.....	118



## TABLolar LİSTESİ

Tablo 1: Sinir sistemi ile yapay sinir ağlarının benzerlikleri .....	8
Tablo 2: Toplama fonksiyonu örnekleri.....	13
Tablo 3: Geçiş fonksiyonu örnekleri .....	14
Tablo 4: Öğrenme algoritmaları .....	25
Tablo 5: Çeşitli sinir ağı modellerinin kuvvetli ve zayıf yönleri.....	36
Tablo 6: Düşük fiyatlamaya ile ilgili çalışmalar .....	43
Tablo 7: Halka açılmanın yararları ve sakıncaları .....	48
Tablo 8: Tanımlayıcı istatistikler.....	66
Tablo 9: Normallik testi .....	67
Tablo 10: Girdi değişkenleri ile çıktı değişkeni ( $\ln P_1$ ) arasındaki korelasyon.....	68
Tablo 11: Düşük Fiyatlamaya İlişkin Formülasyonlar .....	75
Tablo 12: YSA modeline gösterilen girdilerin özet istatistikleri (A seti) .....	81
Tablo 13: A seti için gerçek $P_0$ ve $P_1$ değerlerinin dağılımına ilişkin istatistikler .....	82
Tablo 14: En iyi YSA modelinin parametreleri .....	83
Tablo 15: T-testinin sonuçları (A seti).....	84
Tablo 16: Mann-Whitney U testinin sonuçları (A seti) .....	85
Tablo 17: Çoklu regresyon modelinin sonuçları (A seti).....	87
Tablo 18: YSA ve çoklu regresyon modelinin karşılaştırılması (A seti .....	89
Tablo 19: Küçük şirketler için gerçek fiyatlamaya olasılıkları (A seti test verileri).....	90
Tablo 20: YSA modelinin tahmin performansları (A seti test verileri) .....	90
Tablo 21: Regresyon modelinin tahmin performansları (A seti test verileri) .....	90
Tablo 22: YSA modeline gösterilen girdilerin özet istatistikleri (B seti) .....	92
Tablo 23: Gerçek $P_0$ ve $P_1$ değerlerinin dağılımına ilişkin istatistikler (B seti).....	93
Tablo 24 Büyük şirketler için geliştirilen YSA modeli (B seti).....	93
Tablo 25: T-testinin sonuçları (B seti).....	94
Tablo 26: Mann-Whitney U testinin sonuçları (B seti) .....	95
Tablo 27: Çoklu regresyon modeli sonuçları (B seti).....	97
Tablo 28: YSA ve çoklu regresyon modelinin karşılaştırılması (B seti) .....	99
Tablo 29: Büyük şirketler için gerçek fiyatlamaya olasılıkları (B seti test verileri) ....	100
Tablo 30: YSA modelinin tahmin performansları (B seti test verileri) .....	100
Tablo 31: Regresyon modelinin tahmin performansları (B seti test verileri) .....	100

## ŞEKİLLER LİSTESİ

Şekil 1: Biyolojik nöron yapısı.....	7
Şekil 2: Yapay nöron .....	9
Şekil 3: Yapay sinir ağı katmanlarının birbirleri ile ilişkileri .....	10
Şekil 4: Bir yapay sinir ağı örneği .....	11
Şekil 5: Geçiş fonksiyonları .....	15
Şekil 6: Bir yapay sinir hücresinin çalışma prensibi.....	16
Şekil 7: Yapay sinir ağının eğitim prosedürü.....	17
Şekil 8: Öğretmenli öğrenme yapısı. ....	18
Şekil 9: Öğretmensiz öğrenme yapısı. ....	19
Şekil 10: Destekleyici öğrenme yapısı.....	20
Şekil 11: Öğrenmenin hata uzayındaki gösterimi.....	21
Şekil 12: Çok boyutlu hata uzayı.....	22
Şekil 13: Ağın az öğrenmesi ve ezberlemesi.....	24
Şekil 14: Tek bir yapay nöron için hataların geriye yayımı.....	29
Şekil 15: İleri beslemeli ve geri beslemeli ağların temel yapısı.....	33
Şekil 16: Yapay sinir ağlarının sınıflandırılması.....	34
Şekil 17: Bağlantı yapılarına göre çeşitli ağların mimarileri .....	35
Şekil 18: 1995-2004 yılları arasında gerçekleşen İHA sayısı .....	65
Şekil 19: Normal Olasılık Grafiği (A seti).....	88
Şekil 20: Y tahminlerinin hata terimlerine karşı saçılım grafiği (A seti).....	88
Şekil 21: Normal Olasılık Grafiği (B seti).....	98
Şekil 22: Y tahminlerinin hata terimlerine karşı saçılım grafiği (B seti).....	98
Şekil 23: YSA ve regresyon modellerinden elde edilen tahminlerin gerçek değerlerle karşılaştırılması (A seti eğitim verileri) .....	123
Şekil 24: YSA ve regresyon modellerinin mutlak hata değerlerine göre karşılaştırılması (A seti eğitim verileri) .....	124
Şekil 25: YSA ve regresyon modellerinden elde edilen tahminlerin gerçek değerlerle karşılaştırılması (A seti test verileri).....	125
Şekil 26: YSA ve regresyon modellerinin mutlak hata değerlerine göre karşılaştırılması (A seti test verileri).....	126
Şekil 27: YSA ve regresyon modellerinden elde edilen tahminlerin gerçek değerlerle karşılaştırılması (B seti eğitim verileri) .....	132
Şekil 28: YSA ve regresyon modellerinin mutlak hata değerlerine göre karşılaştırılması (B seti eğitim verileri) .....	133
Şekil 29: YSA ve regresyon modellerinden elde edilen tahminlerin gerçek değerlerle karşılaştırılması (B seti test verileri).....	134
Şekil 30: YSA ve regresyon modellerinin mutlak hata değerlerine göre karşılaştırılması (B seti test verileri).....	135

## **EKLER LİSTESİ**

Ek 1: Geliştirilen en iyi YSA modelinin bağlantı ağırlıkları (A seti).....	119
Ek 2: Geliştirilen en iyi YSA modelinin performans grafikleri (A seti).....	122
Ek 3: B seti için geliştirilen en iyi YSA modelinin bağlantı ağırlıkları.....	127
Ek 4: B seti için geliştirilen alternatif YSA modelleri.....	130
Ek 5: B seti için geliştirilen en iyi YSA modelinin performans grafikleri .....	131



## GİRİŞ

Yapay zekâ alanında son yıllarda yaşanan gelişmeler uzman sistemler, yapay sinir ağları, bulanık mantık ve genetik algoritmalar gibi bilgi işlem teknolojilerini kullanılabilir hale getirmiştir. Bu teknikler içinde yapay sinir ağı teknolojisi, çok sayıda değişkenin birbiri ile karmaşık ilişki içinde bulunduğu örüntüleri *öğrenmesi, ilişkilendirmesi, sınıflandırması, genellebilmesi veya bunların optimizasyonunu bulabilmesi* nedeniyle biyoloji, iş dünyası, çevre, üretim, tıp, askeri ve özellikle finans alanındaki problemlerin çözümünde uygun bir araç durumundadır.

Yapay sinir sistemi, beynin bir işlevi yerine getirme yöntemini modellemek için, beynin fizyolojisinden ve biyolojik öğrenmenin simülasyonundan yararlanılarak oluşturulan bir yapay zeka aracı ve bilgi işleme modelidir. İnsan beyninin çalışma prensibi üzerine oluşturulmuş olan yapay sinir ağları\*, girdi ve çıktı veri kümelerini kullanarak sistem davranışını deneme yolu ile öğrenebilen yapay sistemlerdir.

YSA'nın en önemli özelliği, *öğrenmedir*. Öğrenme, zaman içinde yeni bilgilerin keşfedilmesi yoluyla davranışların iyileştirilmesi sürecidir (Simon, 1983; 25). YSA, herhangi bir olay hakkında bilinen örnekler yoluyla girdiler ve çıktılar arasındaki ilişkiyi - doğrusal olsun veya olmasın- öğrenerek hiç görmediği fakat benzer alandan örneklere kabul edilebilir çözümler üretebilme yeteneğine sahiptirler. Bu özellik YSA'ndaki zeki davranışın temelini oluşturur. YSA yeni bilgiler türetme, yeni bilgiler oluşturma ve keşfetme gibi yetenekleri öğrenme özelliği sayesinde herhangi bir yardım almadan otomatik olarak gerçekleştirebilmektedir.

Öğrenme yeteneği, kolayca farklı problemlere uyarlanabilirliği, genelleme yapabilmesi, daha az bilgi gerektirmesi, paralel yapılarından dolayı hızlı çalışabilme yeteneği ve kolay bir şekilde uygulanabilmesi gibi pek çok avantajından dolayı yapay sinir ağları pek çok alanda farklı problemlerin çözümünde kullanılmaktadır.

---

\* Çalışma içerisinde yapay sinir ağları, bu noktadan itibaren YSA kısaltması ile anılacaktır.

Son günlerde finansal konularda verilen kararların kalitesini artırmak için geliştirilen yapay sinir ağlarına büyük ilgi gösterilmeye başlanmıştır. Global ekonomide rekabet edebilmek ve bunu sürdürebilmek isteyen finansal kuruluşların gün geçtikçe ileri bilgisayar teknolojilerine daha bağımlı hale gelmesiyle, 1990ların başlarından itibaren YSA'nın finansal konulardaki uygulamalarına sıkça rastlanmaya başlanmıştır. (Hsieh, 1993; Shachmurove, 2002; Wong ve Selvi, 1998). Rutin kredi değerlendirme işlemlerinden, finansal tahminlemenin birçok tipine kadar değişen platformda geniş kapsamlı finansal uygulamalarla, YSA yeni bir teknolojiyi bilgi kullanıcılarının hizmetine getirmektedir. Örneğin,

- Portföy yönetimi ve risk kontrolü (Brockett vd., 1994),
- Hisse senedi fiyat indekslerinin ve türev piyasa araçlarının değerlerinin tahmini (Hutchinson vd.,1994; Shachmurove ve Witkowska, 2000; Kaplan 2001),
- Döviz kurlarının tahmini (Tenti, 1996),
- Finansal başarısızlıkların tahmini (Yıldız, 1999),
- Kredi kartı hilelerinin tespiti (Öztemel, 2003)

gibi konularda pek çok yapay sinir ağı uygulaması bulunmaktadır.

YSA teknolojisi, gürültülü veya eksik veriler karşısında bile makul sonuçlar üretebilme yeteneği ile bilinmektedir. YSA teknolojisinin bu özelliği, çoğunlukla gürültülü ya da eksik olan finansal veriler açısından önemlidir. Finansal veriler aynı zamanda doğrusal ilişkilerden çok doğrusal olmayan ilişkilere sahiptir (Shachmurove, 2002). Doğrusal modeller, önemli detayları anlayabildikleri ve açıklayabildikleri takdirde avantajlı olabilirler. Ancak ilgilenilen problemin temelindeki ilişki doğrusal olmadığı durumlarda doğrusal modeller uygun değildir (Tukey, 1960; Zhang vd., 1998). YSA, çok yoğun veri içeren, yapılandırılmamış, yüksek oranda belirsizlik ve gizli ilişkiler içeren modellerde başarılı bir şekilde uygulanabilmektedir. YSA, girdi ve çıktı değişkenleri arasındaki herhangi bir ön bilgiye ve varsayıma ihtiyaç duymadan, doğrusal olmayan ilişkileri modelleyerek veriler arasındaki bilinmeyen ve fark edilmesi güç ilişkileri tanımlayabilme yeteneğine sahiptir (Kaastra ve Boyd, 1996). Bu yeteneği ile YSA teknolojisi,



özellikle doğrusal olmayan ilişkilere sahip çok sayıda değişkenin bulunduğu finansal modellerin asıl odağı olmuştur.

YSA, finansal konularda en çok geleceğin tahminlenmesi konusunda kullanılmaktadır. Yapılan birçok çalışma tahminleme alanında, YSA'nın en az klasik istatistiksel metotlar kadar hatta daha iyi neticeler verdiğini göstermiştir (Hill vd., 1996; Sharda ve Patil, 1992; Tang vd., 1991). YSA'nın özellikle doğrusal olmayan zaman serilerinde gösterdiği başarı, bir tahmin aracı olarak tercih edilmesini sağlamıştır (Zhang vd., 1998). Sinir ağlarının finans alanındaki uygulamaları ile ilgili yazın taramasından, bu alandaki araştırmaların çoğunda yapay sinir ağı modellerinin yapılan tahminin doğruluk derecesine göre istatistiksel modellerden üstün olduğu belirtilirken, bazılarında da tersi durum ile karşılaşıldığı anlaşılmıştır. (Wong ve Selvi, 1998). Aslında, bir tekniğin diğerlerine üstünlüğü durumdan duruma değişmektedir. Bir tekniğin performansı,

- Açıklayıcı değişkenlerin seçimi (Boritz ve Kennedy, 1995),
- Uygulama alanı (Indro vd., 1999),
- Modelde kullanılan verilerin miktarı (Kiang, 2003) ve
- Doğruluk derecesi (Bansal vd., 1993; Klein ve Rossin, 1999)

gibi karakteristiklere bağlıdır.

Bu çalışma, YSA teknolojisinin özelliklerine bağlı olarak, hisse senedini ihraç eden kuruluşun bakış açısından, ilk halka arzların piyasa fiyatının tahminlenmesinde yapay sinir ağlarının kullanımını göstermeyi amaçlamaktadır.

Bir hisse senedinin ilk halka arzı\*, bir şirketin hisse senedini ilk kez halka açması demektir. Şirketler menkul kıymetlerini ihraç ederek sermayenin tabana yayılmasını sağlarlar ve böylece ek sermaye edinirler. İHA fiyatını belirlerken bir şirketi değerlemek, çok sayıda bağımsız ve birbirleri ile ilişkileri belli olmayan değişkenlere bağlıdır. Bu durum, bir yatırımcıyı veya şirketin/aracı kurumun kendisini bir İHA fiyatı ile gelen şirketi analiz etmede zor duruma düşürmektedir.

---

\* Çalışma içerisinde ilk halka arz (IPO: Initial Public Offering), bu noktadan itibaren İHA kısaltması ile anılacaktır.

Bunun yanında İHA'nın fiyatlanması kusurlu ve eksik bilgilere bağlı olarak yapılmaktadır.

İHA fiyatlama problemi, karar sürecine yön vermesi açısından piyasa talebi, ürünün kabulü, rekabet ortamı veya önceki tecrübeye ilişkin az ya da hiçbir bilginin olmadığı yeni ve tek ürünlerin fiyatlanmasına benzemektedir (Jain ve Nag, 1995; 283). Halka açılan şirketler ve aracı kurumları, ilk arz için hisse senedinin fiyatının ne olacağına ilişkin karar vermek durumundadırlar. Hisse senedinin fiyatını belirlemede en çok dikkate alınan faktör, gelecek nakit akışlarının net bugünkü değeridir (Brealey vd., 1997; 376). Fiyatlama kararında en çok dikkate alınan faktörler ise şunlardır (Kim ve Ritter, 1999; McCarthy, 1999; Ritter ve Welch, 2002; Ljungqvist ve Wilhelm, 2003; Aggarwal ve Klapper, 2003):

- Piyasa/talep koşulları,
- Endüstri yapısı,
- Ürünün farklılığı,
- Rekabet ortamı,
- Aracı kurumun itibarı,
- Sahiplik yapısı,
- Hisse senedini ihraç eden firmaya özgü karakteristikler

Hissenin fiyatı belirlenince, şirket, tüm arzı sabit fiyatla halka satmayı taahhüt eder. Şirketin piyasa fiyatı (değeri), İHA'nın ikincil piyasada işlem görmesiyle ortaya çıkar. Eğer hissenin piyasaya çıktıktan sonraki fiyatı İHA fiyatının önemli ölçüde altında (üstünde) olursa, şirket/yatırımcılar düşük fiyatlama (aşırı fiyatlama) şeklinde kayıplara maruz kalır. Öyleyse, ihraç eden kurum ve aracı kurumlarının İHA'ları, gözlenemeyen İHA sonrası piyasa fiyatına mümkün olduğunca yakın fiyatlamaları önemli olduğu vurgulanmalıdır.

Yeni hisseleri gerçekçi bir şekilde fiyatlamaya ihtiyacın olmasına rağmen, çok sayıda ampirik çalışma, İHA'ların ortalama olarak önemli ölçüde düşük fiyatlandığını ortaya çıkarmıştır. Birçok çalışma İHA'nın ortalama düşük fiyatlama oranının %15 i geçtiğini belirtmektedir (Ritter ve Welch, 2002; Dimovski ve Brooks,

2004). Türkiye’de ise, 1990–1995 yılları arasında işlem görmeye başlayan 88 firmanın hisse senetlerinin ilk gnk getirileri ortalama %12.3 olarak bulunmuştur (Kıymaz, 1996).

İlk halka arz edilen hisse senetlerinin fiyatlarının tahminlenmesi alanında, istatistiksel tekniklere alternatif olarak, yapay sinir ađı teknolojisi ile istatistiksel modeller kadar veya daha yksek ngr dođruluđuna sahip bir modelin geliştirlmesi, bu çalışmanın temel amacını oluşturmaktadır. Jain ve Nag (1995), Brennan ve Franks (1997), Pagano, Panetta ve Zingales (1998), Ritter (1998), Kooli ve Suret (2002); Smart ve Zutter (2003) ve Field ve Sheehan (2004) gibi araştırmacıların dşk fiyatlama ile ilgili yapmış oldukları çalışmalarla tutarlı olarak, hisse senedinin piyasaya çıktıktan sonraki fiyatı tahminlenmeye çalışılmıştır. Hisse senedinin piyasaya çıktıktan sonraki fiyatı, ilk kez halka arz edilen hisse senedinin, piyasadaki ilk işlem gnnn sonunda ulaştığı kapanış deđeridir. Bu çalışmanın kapsamında, yapay sinir ađı modellerinin fiyatlama performansları incelenmiş ve ađın rettiđi fiyatlarla çoklu regresyon tekniđi ile elde edilen fiyatlar ve İHA’nın gerek fiyatları karşılaştırılmıştır. Yapay sinir ađı modelinin dođruluk derecesi, ađın gerek ilk işlem gn kapanış fiyatından nemli lde sapmayan bir fiyat dađılımı retme yeteneđi ile llmştr

# 1 ÇALIŞMANIN AMACI, KAPSAMI VE YÖNTEMİ

## 1.1 Çalışmanın Amacı ve Yazına Katkısı

İlk halka arz edilen hisse senetlerinin fiyatlarının tahminlenmesi alanında, istatistiksel tekniklere alternatif olarak, yapay sinir ağı teknolojisi kullanılarak istatistiksel modeller kadar veya daha yüksek öngörü doğruluğuna sahip bir modelin geliştirilmesi, bu çalışmanın temel amacını oluşturmaktadır. Spesifik olarak, YSA'daki hatayı geriye yama teorisini kullanmak ve bir paket program yardımıyla gelecekteki ilk halka arzların ilk gün fiyat performansını doğru bir şekilde tahmin edecek bir model geliştirmede yapay sinir ağının yeteneğini test etmek amaçlanmaktadır. Bunu gerçekleştirdikten sonra, kullanıcılar açısından yapay sinir ağlarının tahminleme aracı olarak kullanımının uygunluğu ve pratikliği konusunda bilgi verilebilecektir. Bu çalışmanın sonucunda elde edilen örnek model, aynı zamanda İHA'nın ilk işlem günü kapanış değerini tahminleyerek, ilk kez halka açılacak şirketlere İHA'yı nasıl fiyatlandırmaları gerektiği konusunda yardımcı olabilecektir.

Yapay sinir ağları, özellikle finans alanındaki uygulamaları açısından oldukça geniş bir yazın altyapısına sahip olmasına rağmen, ilk halka arzların fiyatlanması konusunda pek fazla uygulaması yapılmamıştır. Yazında, sadece 1994 yılında Jain ve Nag'in yazdığı bir makale ve 2001 yılında Lubis'in yaptığı bir doktora tezi bulunmaktadır. Her iki çalışmada da ilk halka arzların fiyatlanmasında yapay sinir ağları kullanılmıştır. Fakat bu çalışmalarda, daha çok hisse senedini ihraç eden şirketin finansal karakteristikleri girdi değişkenleri olarak kullanılmıştır. Bu girdi değişkenleri sürekli değerlere sahiplerdir. Bu çalışmada kullanılan girdi değişkenleri ise farklıdır. Finansal rakamlardan ziyade şirketin kendisine ve İHA sürecine özgü değişkenler kullanılmıştır. Bunların bir kısmı kukla değişken olarak modele girdiğinden, modelin yapısında doğrusal olmayan ilişkiler baskındır. YSA'nın gücü, bu doğrusal olmayan ilişkilerin üstün bir performansla modellenmesinde kullanılmıştır.

## 1.2 Arařtırma Soruları

- YSA ilk halka arzların ilk gn kapanıř fiyatlarını doęru bir Őekilde tahmin edebilir mi?
- Çoklu regresyon ilk halka arzların ilk gn kapanıř fiyatlarını doęru bir Őekilde tahmin edebilir mi?
- YSA, doęruluk derecesi çoklu regresyon modelinden daha yksek olan tahminler yapabilir mi?
- Halka aılmak isteyen Őirketler ilk halka arz fiyatlarını belirlerken, YSA'yı pratik bir tahmin aracı olarak kullanabilir mi?

## 1.3 alıřmanın Kapsamı, Sınırlamaları ve Varsayımları

İlk halka arz edilen hisse senetlerinin fiyatlarını etkileyen faktrler ile kullanılabilir yapay sinir aęı tipinin olası kombinasyonlarının sayısı sınırsızdır. Bu nedenle, arařtırma, ilk halka arzlarda etkisi olan pek çok deęiřken arasından seilen birkaç deęiřken, bir YSA tipi ve bir istatistiksel tahminleme aracı ile sınırlandırılmıřtır. Bu nedenle, oluřturulan rnek karar destek modeli tm verileri kullanmamaktadır.

Bu alıřmadaki dięer sınırlamalar ise, verilerin elveriřlilięi ve kullanılan paket programın model geliřtirme konusundaki kapasitesidir. Trkiye'deki sermaye piyasası, 1986 yılından itibaren etkinlięini kazanmıř olmasına raęmen, 1995 yılı ncesi hisse senetleri ve bunları ihra eden Őirketlerin bilgilerine tam olarak ulařılamadıęından, alıřma 1995-2004 arasındaki ilk halka arz edilen hisse senetleri ile sınırlandırılmıřtır. Fakat bu aęın etkinlięini azaltmamıřtır. Kullanılan paket programın mnsndeki parametre deęiřiklikleri ok esnek olmadıęından, sınırlı sayıda fonksiyonlar kullanılabilmiřtir.

Halka arzların ilk gn fiyat performansı, hisse senedinin piyasaya girdięi ilk iřlem gn sonundaki kapanıř fiyatı ile deęerlendirilmektedir.

## 1.4 Araştırmanın Yöntemi

Bu çalışma yürütülürken kullanılan yöntem aşağıda özetlenmiştir.

İlk olarak, ilk halka arzlar ve yapay sinir ağları konusunda yazın taraması yapılmıştır.

- Yazın taraması makaleler, kitaplar, tezler ve internet kaynakları üzerinden yapılmıştır. Aynı zamanda her iki konunun uzmanları ile teorik ve teknik konular üzerinde birebir görüşmeler yapılmıştır.
- Yapay sinir ağları konusunda, geriye yayma algoritmasının matematiksel teorisi detaylı olarak incelenmiştir.

Tahmini yapılacak olan bilgi (ilk halka arzların piyasa fiyatı) belirlenmiştir.

- Neyin tahmininin yapılacağı ve bu tahminin geleceğin hangi noktası için yapılacağı belirlenmiştir. “Hisse senedinin piyasaya çıktığı ilk günün sonundaki kapanış fiyatı”
- Yapay sinir ağının girdileri, ilk halka arzların teorik çerçevesi dahilinde belirlenmiştir.

Araştırma kapsamının belirlenmesi ile geçmiş veriler toplanmış ve bu veriler MS Excel ile ön işleme tabi tutulup düzenlenmiştir.

- Elde edilen veriler şirket büyüklüklerine göre ikiye ayrılıp, her bir veri seti için ayrı bir model oluşturulmuştur.
- Geçmiş veriler kullanılarak, paket programla ağ eğitilip, performansı değerlendirilmiştir.
- Gerektiğinde, ağın girdileri yeniden düzenlenmiş, yeniden eğitilmiş ve performansları incelenmiştir.
- Çoklu doğrusal regresyon tekniği kullanılarak tahminleme yapılmıştır.
- İstatistiksel olarak ağın tahminleri ile regresyon tahminleri bilimsel anlamlılık açısından karşılaştırılmıştır.
- Bayes teoremi kullanılarak her iki yöntemin başarılı bir tahmin yapma olasılıkları hesaplanmıştır.

## 2 YAPAY SİNİR AĞLARI

İnsan beyni, insanlığın bildiği en karmaşık bilgi işleme birimidir. Beynin işleyişini daha iyi anlayabilmek için, birçok bilim adamı yapay zekâ alanındaki gelişmeler doğrultusunda beynin çeşitli yeteneklerini, özellikle öğrenme yeteneğini, taklit etmeye çalışmaktadır. Yapay Sinir Ağları teknolojisi, en basit tanımıyla, insan beyninin biyolojik yapısına benzer şekilde oluşturulan ve bir grup değişken arasındaki örüntüleri tanımlamaya çalışan matematiksel bir modeldir. Bunu ise, insan beyninin en önemli bileşeni olan biyolojik hücreler, ya da yazındaki adıyla nöronlar gibi işlev gösteren bilgisayar işlem birimlerini bir araya getirerek gerçekleştirir. Karar hızı açısından insan beyni ile yarışabilecek aşamayı henüz kat edememiş olmalarına rağmen, karmaşık eşleştirmelerin hassas bir biçimde gerçekleştirilebilmesi ve yapısal gürbüzlüğe sahip olmaları nedeniyle gün geçtikçe Yapay Sinir Ağlarının uygulama alanları genişlemekte ve modern bilişim teknolojileri sayesinde gerçeğe daha yakın sonuçlar üretmektedirler.

Yazında çok sayıda (100'den fazla) yapay sinir ağı modeli vardır. Bazı bilim adamları, beynimizin güçlü düşünme, hatırlama ve problem çözme yeteneklerini bilgisayara aktarmaya çalışırken, bazıları ise, beynin fonksiyonlarını kısmen yerine getiren birçok model oluşturmaya çalışmışlardır. YSA, insan beyninin fonksiyonel özelliklerine benzer şekilde, öğrenme, ilişkilendirme, sınıflandırma, genelleme, özellik belirleme ve optimizasyon gibi konularda başarılı bir şekilde uygulanmaktadır. Örneğin(Kalyanpur ve Simon, 2001; Hamzaçebi ve Kutay, 2004; Baykasoğlu ve Özbakır, 2004; Januskevicius, 2003; Atiya, 2001);

- Pacman bilgisayar oyununun performansını artırma,
- Uzun dönemli elektrik enerjisi tüketiminin tahmini,
- Üretim çizelgeleme sistemlerinde teslim tarihlerinin belirlenmesi,
- Yazılı bir metnin konuşmaya çevrilmesi,
- El yazısı karakterlerini tanıma,
- Bir müzik eserini çalma,
- Bir otomobil motorunun ateş almaması durumunun tespiti,
- Piyasa etkinliğini test etme,

- İflasın tahmini

gibi pek çok konuda yapay sinir ağı uygulamaları bulunmaktadır.

## 2.1 Yapay Sinir Ağlarının Gelişim Kronolojisi

YSA araştırma alanı yoğun faaliyetlerle geçen üç dönem yaşamıştır (Öztemel, 2003; 37–40), (Krycha ve Wagner, 1999; 186), (Jain ve Mao, 1996; 33), (Freeman ve Skapura, 1991) :

1. dönem: YSA'nın dayandığı ilk hesaplama modelinin temelleri, 1940'ların başında araştırmalarına başlayan McCulloch (nörobiyolojist) ve Pitts (istatistikçi)'in, 1943 yılında yayınladıkları "*Sinir Aktivitesindeki Düşüncelere Ait Bir Mantıksal Hesap*" başlıklı bir makale ile atılmıştır. Bu öncü çalışma, ilk dijital bilgisayarların da ilham kaynağıdır. Hebb, McCulloch ve Pitts'in ilk yapay sinir hücresinin yapısını oluşturmalarının ardından, 1949 yılında Hebb, "*Hebbian öğrenme*" kuralı denilen ve günümüzde birçok öğrenme kuralının temelini oluşturan bir öğrenme kuralı geliştirmiştir. Bu bilim adamları, öğrenmenin ve zekânın herhangi bir özelliğinin simülasyonunda bilgisayarların aktif olarak nasıl kullanılabileceğini, 1956 yılında düzenlemiş oldukları ilk yapay zekâ konferansında tartışmışlardır.

2. dönem: Bronx Yüksek Bilim Okulu'ndan Frank Rosenblatt, 1958 yılında ilk kez algılayıcı (perceptron) modelini geliştirmiştir. Bu model, YSA tarihinde önemli gelişmelere öncülük etmiştir. 1959'da, Stanford üniversitesinden Bernard Widrow, basit nöron benzeri elemanlara dayanan ve "adaline" (Adaptive Linear Neuron) olarak adlandırılan bir adaptif doğrusal elemanı geliştirmiştir. Adaline ve iki tabakalı biçimi olan "madaline" (Multiple Adaline); ses tanıma, karakter tanıma, hava tahmini ve adaptif kontrol gibi çok çeşitli uygulamalar için kullanılmıştır. Daha sonraları adaline, kesikli bir çıktı yerine sürekli bir çıktı üretmek için geliştirilmiştir. Widrow, telefon hatları üzerindeki ekoları elimine etmeye yarayan adaptif filtreleri geliştirmede, adaptif doğrusal eleman algoritmasını kullanmıştır. Bununla ilk defa YSA gerçek bir probleme uygulanmıştır. 1960larda yapay zekâ alanının önde gelen



isimlerinden Minsky ve Papert'ın Perseptron isimli kitaplarında, tek bir algılayıcının kısıtlarını göstererek YSA'nın temel olarak ilgi çekici konular olmadığını belirtmeleri birçok araştırmacının bu alanda çalışmaktan vazgeçmelerine sebebiyet vermiştir. Minsky ve Papert'ın elde ettiği sonuçlar, bir çok (özellikle bilgisayar bilimi alanındaki) araştırmacının hevesini kırmıştır,. YSA alanındaki bu durgunluk dönemi yaklaşık 20 yıl sürmüştür.

3. dönem: 1980'lerin başından itibaren YSA'na olan ilgi yeniden ortaya çıkmıştır. Bu yeniden dirilişin altındaki başlıca gelişmeler, 1982'de Caltech fizikçisi Hopfield'ın moleküller biyolojiden beyin kuramcılığına geçiş yapan modelini tanıtmaması ve Werbos'un ilk kez çok katmanlı algılayıcıların (çok katmanlı ileri beslemeli ağlar), geriye doğru yayma algoritmasını sunmasıdır. Bu algoritma defalarca gündeme getirilmiş olmasına rağmen, 1986'da Rumelhart ve arkadaşlarının çok katmanlı algılayıcı modelin temellerini anlattıkları çalışmaları ile popüler olmuştur. 1987 yılında yapılan ilk yapay sinir ağları sempozyumundan sonra YSA uygulamaları yaygınlaşmıştır.


Günümüzde, YSA ile ilgili araştırmalar yapan çok sayıda bilim adamı ve araştırma grupları vardır. Farklı bilim ve ilgi alanlarında çalışan birçok araştırmacı, birçok yeni gelişmeleri sunmaya devam etmektedir.

## 2.2 Yapay Sinir Ağlarının Biyolojik Temeli

YSA teorisi, yapay zekâ alanındaki bilişsel yetenekli makinelerin tasarlanması ile ilgili araştırmalardan ortaya çıkmıştır. Bir yapay sinir ağı, tıpkı insan beyni gibi öğrenebilecek şekilde tasarlanan bir makine ya da bir bilgisayar programıdır. Haykin (1994) YSA'nı adaptif bir makine olarak tanımlar. YSA, beyni iki yönüyle taklit eder: (i) Ağ bilgiyi öğrenme süreci ile elde eder. (ii) Sinaptik ağırlıklar olarak bilinen nöronlar arasındaki bağlantılar, bilgiyi saklamakta kullanılır.

Beynin ve yapay sinir ağının temel yapı taşı, sinir hücresi ya da yazındaki adıyla nöron olarak bilinir. Şekil 1, bir nöronun ve bağlantılarının nörobiyolojik yapısını gösterilmektedir. Bir nöron başlıca dört kısımdan oluşur:

Hücre gövdesine giren sinyal alıcı lifler (dendrit): Dendritler komşu nöronlardan gelen sinyalleri (impuls) alıp, soma hücreesine ulaştırırlar. Bir nöronun yüzlerce, bazen de binlerce dendrit çıkabilir. Bunların uzunluğu genellikle bir milimetreden daha kısadır. Bazıları ise birkaç milimetre uzunluğa ulaşabilir.



Şekil 1: Biyolojik nöron yapısı

Gövdeden çıkan sinyal iletilen lifler (akson): Nöronun oluşturduğu elektrik sinyalini dendritlere taşıyan liflerdir. Dendritler bu sinyalleri sinapslere göndererek buradan diğer nöronlara iletilir. Bir hücrenin tek bir akson uzantısı bulunur.

Sinapsler: Nöronlar arasındaki bağlantılardır. Bunlar fiziksel bağlantılar olmayıp bir hücreden diğerine elektrik sinyallerinin iletilmesini sağlayan boşluklardır. İki hücrenin birbirleri ile bilgi alışverişini bu sinaptik bağlantılarda kimyasal iletilenler (neurotransmitter) yolu ile sağlar.

Hücre gövdesi (soma hücresi): Dendritler yoluyla gelen sinyalleri işleme tabi tutar ve nöron burada kendi elektrik sinyalini oluşturur. Soma hücresi, nukleus adı verilen hücre çekirdeğini içermektedir ve bu çekirdek, hücrenin yaşamasını sağlayan işlevleri görür. Sinapsler aracılığıyla dendritlere geçirilen iletiler birleşerek akson üzerinde elektriksel bir çıktı oluştururlar. Bu çıktının olup olmayacağı veya çıktının elektriksel yoğunluğu, sinapslerin etkileri sonucu hücreye gelen tüm girdilerin toplam değeri tarafından belirlenir. Somaya gelen girdilerin ağırlıklı toplamı akson üzerinde çıktı oluşturacak değere (eşik değer) ulaştığında, bu durum nöron ateşlendi (fired) olarak ifade edilir. Bu şekilde girdiler nöron tarafından değerlendirilerek çıktıya dönüştürülmüş olur.

Beynimizde  $10^{10}$  adet nöron ve bunların da  $6 \times 10^{13}$ 'ten fazla sayıda bağlantısının olduğu söylenmektedir. İnsan beyni, çok hızlı çalışabilen mükemmel bir bilgisayar gibi görülebilir. Örneğin, bir grup insan resmi içinden tanıdık bir resmi 100–200 ms gibi kısa bir sürede fark edebilir. Biyolojik sinir ağlarının performansları küçümsenmeyecek kadar yüksek ve karmaşık olayları işleyebilecek yetenektedir. YSA ile bu yeteneğin bilgisayara kazandırılması amaçlanmaktadır. YSA, insan beyninin çalışma prensibi örnek alınarak geliştirilmeye çalışılmıştır ve aralarında yapısal olarak bazı benzerlikler vardır (Jain ve Mao, 1996; 33–34). Bu benzerlikler Tablo 1'de verilmiştir.

Tablo 1: Sinir sistemi ile yapay sinir ağlarının benzerlikleri.

Sinir sistemi	YSA sistemi
Nöron	İşlem elemanı (yapay nöron)
Dendritler	Toplama fonksiyonu
Hücre gövdesi	Aktivasyon (Geçiş) fonksiyonu
Akson	Eleman çıktısı
Sinapslar	Ağırlıklar


## 2.3 Yapay Sinir Ağlarının Temel Yapısı

Yapay sinir ağıyla aslında biyolojik sinir ağının bir modeli oluşturulmak istenmektedir. Bunun için, mevcut olan birçok bilgisayar donanım ve yazılım teknolojilerinin yanı sıra, sadece YSA için geliştirilmiş paralel işlem yapan özel donanımlı bilgisayarlardan da faydalanılabilmektedir.

### 2.3.1 Yapay Sinir Ağlarının Bileşenleri

#### 1. Yapay Nöronlar (İşlem Elemanları)

Bir yapay sinir ağı modelinin temel birimi, Şekil 2’de gösterilen yapay sinir hücresidir, buna işlem elemanı da denilmektedir. Ağ içinde yer alan tüm nöronlar, bir veya birden fazla girdi alır, bunları işler ve çıktıya dönüştürürler.



Şekil 2: Yapay nöron

#### 2. Yapay Sinir Ağının Bağlantı Yapısı


Yapay nöronlar birbirleriyle bağlantılar aracılığıyla bir araya gelerek yapay sinir ağını oluştururlar. Nöronların bir araya gelmesi rasgele değil, aynı doğrultu üzerinde katmanlar halinde olmaktadır. Katmanların değişik şekilde birbirleriyle

bağlanmaları değişik ağ mimarilerini doğurur. Bir ağ mimarisi (ağın topolojisi), nöronlar arasındaki bağlantı tiplerine, katman sayısına ve nöron sayısına bağlıdır. Yapay sinir ağı mimarileri, 1.3.6 bölümünde ele alınacaktır. Genel olarak nöronlar 3 katman halinde bir araya gelerek ağı oluştururlar (Şekil 3).

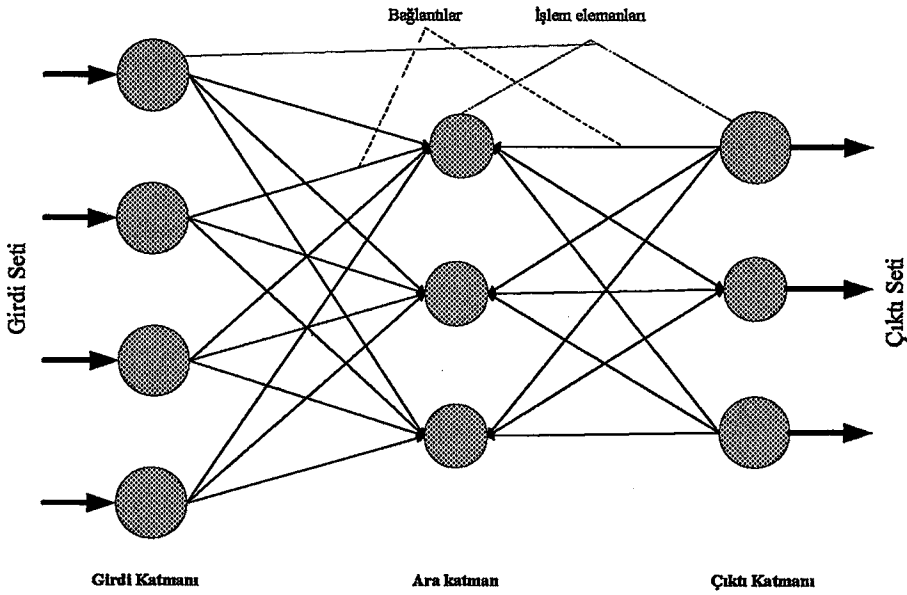
Girdi katmanı: Dış dünyadan bilgileri alıp, ara katmanlara iletmekten sorumludur. Bazı ağlarda bu katmanda bilgi işleme olmamaktadır.

Ara katmanlar: Girdi katmanından gelen bilgileri işleyerek çıktı katmanına gönderirler. Ara katmanlar, özellik detektörü gibi çalışırlar. Bu katmandaki her bir nöron, girdilerdeki kritik bir veya birden fazla özelliği araştırır ve bulduğunda da güçlü bir tepki verir. Buradaki özellik detektörleri bir öğrenme prosedürü ile yaratılır (Hsieh, 1993; 13). Bir ağ için birden fazla ara katmanı olabilir.

Çıktı katmanı: Ara katmandan gelen bilgileri (özellikler kombinasyonunu) işleyerek ağın girdi katmanından sunulan girdi seti (örnek) için üretmesi gereken çıktıyı üretirler. Üretilen çıktı dış dünyaya gönderilir.



Şekil 3: Yapay sinir ağı katmanlarının birbirleri ile ilişkileri



Şekil 4: Bir yapay sinir ağı örneği

Üç katmanın her birinde bulunan nöronlar ve katmanlar arası ilişkiler Şekil 4'de şematik olarak gösterilmiştir. Her katmanda birbirine paralel elemanlar söz konusudur. Nöronları birbirine bağlayan bağlantıların ağırlık değerleri öğrenme sırasında belirlenmektedir.

### 2.3.2 Yapay Sinir Ağlarının İşleyişi

Yapay sinir ağının bilgi işleme faaliyetini yerine getirmesinde 5 temel eleman rol oynamaktadır:

1. **Girdiler:** Bir nörona dış dünyadan veya diğer nöronlardan gelen bilgilerdir. Girdiler, ham veri, başka bir nöronun çıktısı veya kendisinin tekrar girdisi olabileceği gibi, çıktılar da nihai çıktı ya da başka bir nöronun girdisi olabilirler.

Her girdiye tek bir özellik karşılık gelir. Örneğin, ilk halka arzların fiyatlanması probleminde, halka açılan şirketin kaldıraç oranı bir özelliktir ve bu

özelliğın aldığı deęer ađın girdisini oluřturur. Bazı durumlarda girdilerin nümerik bilgiler ile hiçbir ilgisi yoktur. Mesela aynı problemde, řirketin halka açıldıđı yılda kriz olup olmaması ilk halka arz fiyatını etkileyebilir. Kriz durumu da bir özelliktir fakat bu özellik alfa nümerik deęerlerle ifade edilir. Bu durumda kriz özelliğinin varsa 1 yoksa 0 řeklinde ađa nümerik olarak gösterilmesi gerekir. Bazen girdiler tamamen nümerik olsa bile bazı düzenlemeler gerekebilir. Bu düzenleme, girdilerin ölçeklendirilmesi yoluyla yapılabilir.

Girdi ve çıktıların ölçeklendirilerek ađa sunulması ađın performansını yakından etkilemektedir. Ölçeklendirme deęişik řekillerde ve deęişik yöntemlerle yapılabilir. Genellikle girdi vektörü normalize edilerek ya da ařađıdaki gibi bir formülasyon ile örnekleri oluřturan deęerleri belirli bir aralık içine çekerek ölçeklendirilmektedir.

$$x' = \frac{x}{|X|}$$

$x'$ : ölçeklendirilmiş yeni girdi deęeri  
 $x$ : girdi deęeri  
 $|X|$ : girdi vektörünün büyüklük deęeri

$$x' = \frac{x - x_{\min}}{x_{\max} - x_{\min}}$$

$x'$ : ölçeklendirilmiş yeni girdi deęeri  
 $x_{\min}$ : girdi deęerlerinin en küçüğü  
 $x_{\max}$ : girdi deęerlerinin en büyüğü

2. **Ađrılıklar**: Bir yapay sinir ađındaki en önemli unsurlardan biri de bađlantılardır. Nöronlardan birbirlerine bilgi aktarımını sađlayan bađlantılar aynı zamanda bir ađrılık deęerine sahiptirler. Bu ađrılık deęeri, bir nörona gelen bilginin önemini ve hücre üzerindeki etkisini gösterir. Ađrılıkların büyük ya da küçük olması önemli veya önemsiz olduđu anlamına gelmez. Bir ađrılığın deęerinin sıfır olması o ađ için en önemli olay olabilir. Ađrılıklar deęişken ya da sabit deęerler olabilirler.

3. **Toplama fonksiyonu**: Bu fonksiyon, bir hücreye gelen net girdiyi hesaplar. Bunun için deęişik fonksiyonlar kullanılmaktadır. Bir problem için en uygun toplama fonksiyonunu belirlemek için bulunmuş bir formül yoktur, genellikle deneme-yanılma yolu ile belirlenmektedir. Elde edilen toplam, nörona gelen toplam ađrılıklı uyarıyı oluřturur. Tablo 2'de deęişik toplama fonksiyonlarına örnekler verilmektedir. En yaygın olanı ađrılıklı toplamı bulmaktır. Buna göre ađa gelen net girdi ařađıdaki formül ile bulunur.

$$NET = \sum x_i w_{ij}$$

Burada  $x_i$  i'inci girdiyi,  $w_{ij}$  j'inci elemandan i'inci elemana bağlantı ağırlığını, n ise bir hücreye gelen toplam girdi sayısını göstermektedir.

Tablo 2: Toplama fonksiyonu örnekleri

<b>Net Girdi</b>	<b>Açıklama</b>
<b>Çarpım</b> Net Girdi= $\prod x_i w_i$	Ağırlık değerleri girdiler ile çarpılır ve daha sonra bulunan değerler birbirleri ile çarpılarak net girdi hesaplanır.
<b>Maksimum</b> Net Girdi= $\text{Maks}(x_i w_i), i=1, \dots, N$	N adet girdi içinden ağırlıklar ile çarpıldıktan sonra en büyüğü yapay sinir hücresinin net girdisi olarak kabul edilir.
<b>Minimum</b> Net Girdi= $\text{Min}(x_i w_i), i=1, \dots, N$	N adet girdi içinden ağırlıklar ile çarpıldıktan sonra en küçüğü yapay sinir hücresinin net girdisi olarak kabul edilir.
<b>Çoğunluk</b> Net Girdi= $\sum \text{sgn}(x_i w_i)$	N adet girdi içinden ağırlıklar ile çarpıldıktan sonra pozitif ve negatif olanların sayısı bulunur. Büyük olan sayı hücrenin net girdisi olarak kabul edilir.
<b>Kümülatif Toplam</b> Net Girdi= $\text{Net}(\text{eski}) + \sum(x_i w_i)$	Hücreye gelen bilgiler ağırlıklı olarak toplanır ve daha önce gelen bilgilere eklenerek hücrenin net girdisi bulunur.

Kaynak: Öztemel, 2003; 50

4. Geçiş (Aktivasyon) Fonksiyonu: Toplam fonksiyonu bir nöronun ne düzeyde uyarılacağını belirleyen bir fonksiyondur (Vemuri, 1992; 43). Bir nöronun, uyarılma düzeyinin hangi seviyesinden sonra çıktı üreteceği ve çıktının uyarılma düzeyi ile ilişkisi ise, geçiş fonksiyonu tarafından belirlenmektedir. Bu fonksiyon, hücreye gelen net girdiyi işleyerek hücrenin bu girdiye karşılık üreteceği çıktıyı belirler. Geçiş fonksiyonu, çıktının hangi aralıklarda olacağını belirlemesi ve özellikle çok katmanlı ağlar için, her katmanın operasyonları arasında anlamlı bir değer aralığının oluşturulması için de önemlidir. (Rao, 1995;125–127). Çünkü toplam fonksiyonu tarafından üretilen değer oldukça büyük olabilir ve değer çıktı için kullanıldığında, birkaç katman sonra çıktı değeri çok büyük değerlere ulaşabilir. Bu nedenle, çıktının 0,1 veya bazen -1,+1 aralığına dönüştürülmesi gerekir (Trippi ve Turban, 1996; 8–9).



YSA'nda nörona gelen girdi değerlerine önce toplama fonksiyonu uygulanır ve her bir nöronun çıktı (Ç) değeri aşağıdaki formül ile bulunur.

$$\zeta = \sum_{i=1}^N x_i w_{ij} - \theta_i$$

$\theta_i$  eşik (threshold) değeridir. Bu değer, ağlarda nöronların değerlerinin ve dolayısıyla ağın çıktısının sıfır olmasını önlemek için kullanılmaktadır. Eşik değerinin girdisi daima 1'dir.

Daha sonra bu çıktı değerleri bir geçiş fonksiyonuna yani öğrenme eğrisine uygulanarak hücrenin çıktı değeri elde edilir. Toplama fonksiyonunda olduğu gibi geçiş fonksiyonu olarak da çıktıyı hesaplamak için değişik formüller kullanılmaktadır. YSA'nda en çok kullanılan geçiş fonksiyonları Tablo 3'te verilmiştir.

Tablo 3: Geçiş fonksiyonu örnekleri

**Geçiş Fonksiyonu**  
**Sigmoid**

$$f(NET) = \frac{1}{1 + e^{-NET}}$$

$$f \in [0,1]$$

**Doğrusal fonksiyon**

$$f(NET) = NET,$$

$$f \in (-\infty, +\infty)$$

**Hiperbolik tanjant fonksiyonu**

$$f(NET) = (e^{NET} - e^{-NET}) / (e^{NET} + e^{-NET}),$$

$$f \in [-1,1]$$

**Sert geçişli fonksiyonu**

$$f(NET) = \begin{cases} 1, & \text{eğer } NET > \text{ eşik değeri;} \\ 0, & \text{eğer } NET \leq \text{ eşik değeri} \end{cases}$$

$$f \in \{0,1\}$$


**Açıklama**

YSA'nda en çok kullanılan geçiş fonksiyonudur. 0 ve 1 arasında değerler alabilir. Bunların dışında değerler alamaz (Şekil 5a).

Gelen girdiler olduğu gibi hücrenin çıktısı olarak kabul edilir. Doğrusal YSA'nda ve katmanlı YSA'nın çıktı katmanında kullanılır. Bu fonksiyon, nöronun girdisini doğrudan nöronun çıktısı olarak verir (Şekil 5b).

Gelen NET girdi değerinin bipolar özelliğe sahip olan tanjant hiperbolik fonksiyonundan geçirilmesi ile hesaplanır. Girdi uzayının genişletilmesinde etkili bir geçiş fonksiyonudur (Şekil 5c).

Gelen NET girdi değerinin belirlenen bir eşik değerinin altında veya üstünde olmasına göre hücrenin çıktısı 1 veya 0 değerlerini alır. Sert geçişli fonksiyon, mantıksal çıktı değeri verir ve sınıflandırıcı ağlarda tercih edilir (Şekil 5d).



Şekil 5: Geçiş fonksiyonları

5. *Hücrenin çıktısı*: Geçiş fonksiyonu tarafından belirlenen çıktı değeridir. Şekil 6'da yapay hücrenin çıkışında kullanılan sigmoid fonksiyonuna göre çıktı değerinin hesaplanması gösterilmiştir. Bu nöronun çıktı değeri, diğer işlem elemanlarının girdisi veya ağı çıktısı olabilir.

Çıktılar da, girdilerde kullanılan yöntemlerle ölçeklendirilebilir.

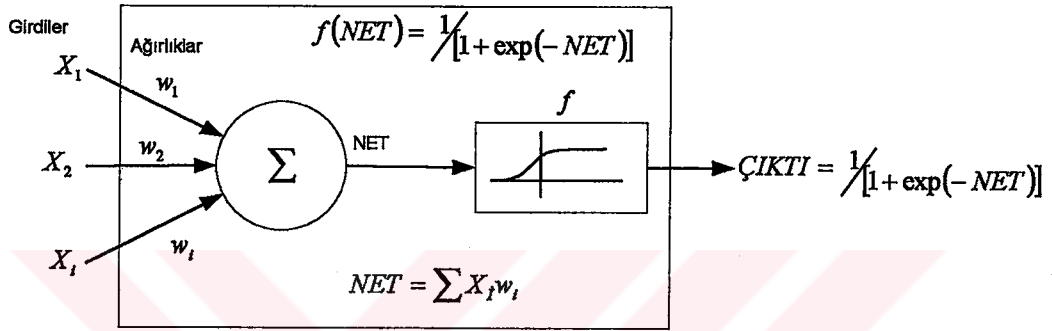
Özetle; her bir nöron girdilerin toplamını ve bir aktivasyon fonksiyonu kullanarak bir çıktı hesaplamaktadır. Spesifik olarak nöronlar, aşağıdaki fonksiyonları yerine getirmektedir:

1. Diğer nöronlardan sinyaller alınır [ $X_0, X_1, X_2$ ]
2. Bu sinyaller kendilerine karşılık gelen ağırlıklarla çarpılır [ $W_0X_0, W_1X_1, W_2X_2$ ]
3. Ağırlıklı sinyaller toplanır [ $\text{Toplam} = W_0X_0 + W_1X_1 + W_2X_2$ ]
4. Hesaplanan toplam bir aktivasyon fonksiyonundan geçirilir. [ $f(\text{Toplam})$ ]
5. Aktivasyon fonksiyonunun çıktısı diğer nöronlara gönderilir [1-4 adımları tekrarlanır] (DeTienne ve Lewis, 2003; 5)

YSA'nın genel olarak çalışma prensibi, bir girdi setini (örnekleri) alarak onu çıktı setine çevirmektir. Bunun için ağı kendisine gösterilen girdiler için doğru çıktıları üretecek hale gelmesi yani eğitilmesi gerekmektedir. Ağa gösterilecek olan örnekler öncelikle bir vektör haline getirilir. Bu vektör ağa gösterilir ve ağ bu vektör

için gerekli çıktı vektörünü üretir. Ağırlık parametre değerleri doğru çıktıyı üretecek şekilde düzenlenir.

Bir yapay sinir ağı, herhangi bir girdi vektörünü çıktı vektörüne nasıl dönüştürdüğü konusunda bir bilgi vermez. Bu nedenle mühendislik biliminde buna kara kutu yakıştırması yapılmaktadır. Kara kutu, dışarıdan bilgileri alıp, dışarıya ürettiği çıktıları vermektedir. İçeride neler olduğu bilinmemektedir. Yani, YSA'nın sonuçları nasıl oluşturduğunu açıklama yeteneği yoktur. Bu ağa olan güveni sarsmakla beraber, başarılı uygulamalar YSA'na olan ilgiyi artırmaktadır.



Şekil 6: Bir yapay sinir hücresinin çalışma prensibi

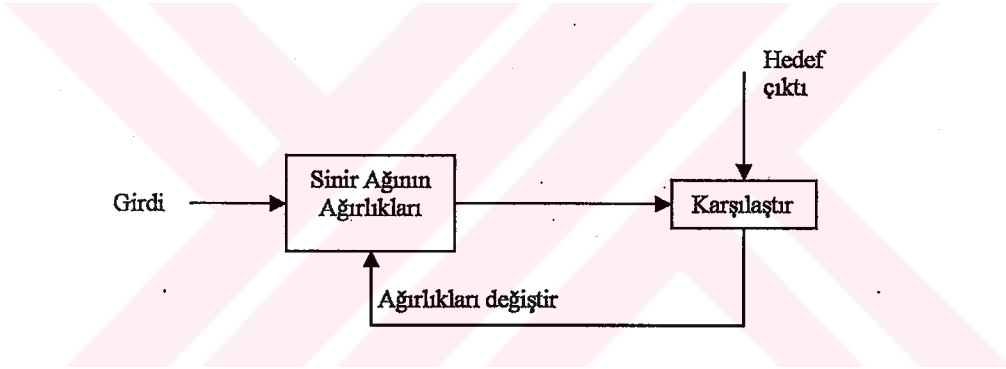
### 2.3.3 Yapay Sinir Ağlarında Öğrenme

Öğrenme yeteneği, insan zekâsının temel özelliğidir. Yapay sinir ağlarını çekici kılan, otomatik olarak örneklerden öğrenebilme yeteneğidir. Simon (1983), öğrenmeyi "zaman içinde yeni bilgilerin keşfedilmesi yoluyla davranışların iyileştirilmesi süreci" olarak tanımlamaktadır. Buradaki zaman içerisinde iyileşme kavramı, zaman içerisinde tecrübe kazanmayı ifade etmektedir. YSA'dan da aslında beklenen, olayları tecrübe kazanarak öğrenmesidir.

YSA'nın öğrenme süreci basitçe şu adımlardan oluşur:

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

YSA'nda nöronların bağlantı ağırlıklarının belirlenmesi işleme ağı eğitilmesi denilmektedir (Rao, 1995; 24). Başlangıçta bu ağırlık değerleri genellikle rasgele atanmaktadır. YSA'na örnekler gösterildikçe, gerçekleşen ve beklenen çıktı arasındaki farka (hataya) göre, bu ağırlık değerleri değiştirilir (Şekil 7). Amaç ağa gösterilen örnekler için doğru çıktıları üretecek ağırlık değerlerini bulmak, yani hatayı minimize etmektir. Ağı doğru ağırlık değerlerine ulaşması ise, örneklerin temsil ettiği olay hakkında genellemeler yapabilme yeteneğine kavuşması demektir. Bu yeteneğe kavuşması işleme ağı öğrenmesi denir (Detienne ve Lewis, 2003; 6).

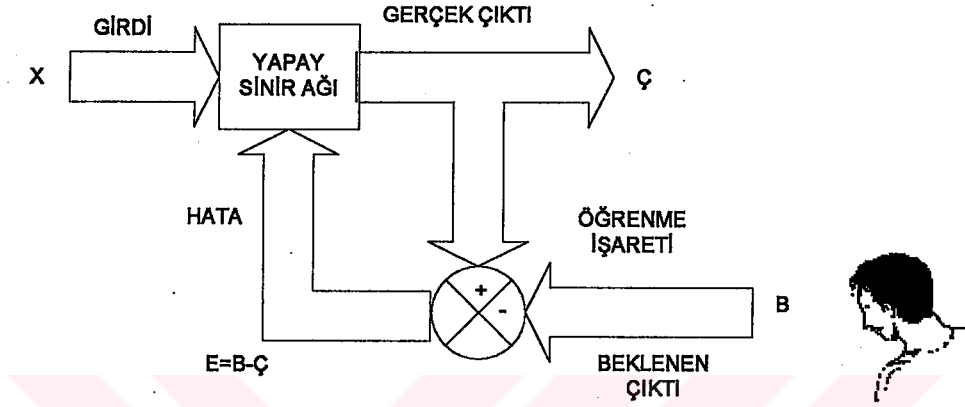


Şekil 7: Yapay sinir ağının eğitim prosedürü

Yapay sinir ağında bilgi, ağı bağlantılarının sahip olduğu ağırlık değerlerinde saklanır, yani ağı zekâsı bağlantılardaki ağırlık değerlerinde saklıdır. Ağırlık değerlerinin tüm ağ içine, dolayısıyla bilginin tüm ağa yayılmış (dağıtık hafıza özelliği) olmasından dolayı, bazı ağırlık değerlerinin kaybolması durumunda bile ağ çalışmasını sürdürebilmektedir (Öztemel, 2003; 56). Bu durumda, ağırlık değerleri ne kadar doğru ise ağı performansı o kadar yüksek olacaktır.

YSA'da ağırlıkların değişmesi öğrenme kurallarına göre yürütülmektedir (Jain ve Mao, 1996; 35). Üç temel öğrenme metodu ve bunların uygulandığı değişik öğrenme kuralları bulunmaktadır:

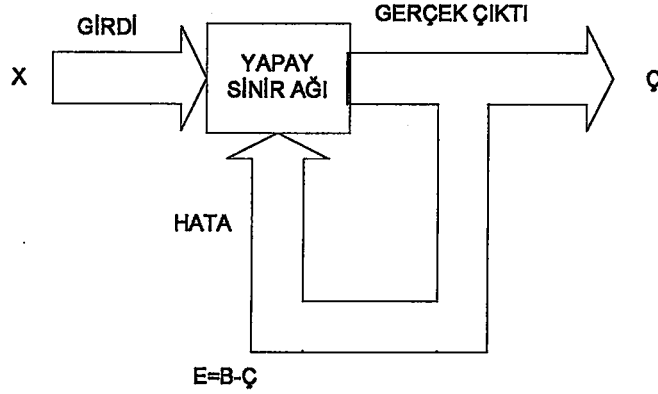
### 1. Öğretmenli Öğrenme (Supervised Learning)



Şekil 8: Öğretmenli öğrenme yapısı.

Öğretmenli öğrenmede, öğrenen sistemin olayı öğrenebilmesine bir öğretmen yardımcı olmaktadır. Öğretmen sisteme öğrenilmesi istenen olay ile ilgili örnekleri girdi/çıkı seti olarak verir (Kröse ve Smagt, 1996;18). Sistemin görevi, her bir girdinin öğretmenin belirlediği çıktıya mümkün olduğunca yakın çıktılar üretecek şekilde ağırlıkları belirlemektir. Bunun için, istenilen ve gerçek çıktı arasındaki hata minimize edilmeye çalışılır (Şekil 8). Widrow-Hoff tarafından geliştirilen delta kuralı ve Rumelhart ve McClelland tarafından geliştirilen genelleştirilmiş delta kuralı veya geri besleme (back propagation) algoritması öğretmenli öğrenme algoritmalarına örnek olarak verilebilir.

## 2. Öğretmensiz Öğrenme (Unsupervised Learning)



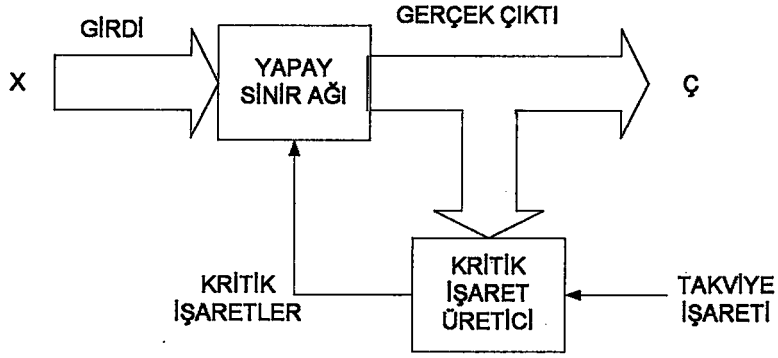
Şekil 9: Öğretmensiz öğrenme yapısı.

Bu tür stratejide sistemin öğrenmesine yardımcı olan herhangi bir öğretmen yoktur. Sisteme sadece girdi değerleri gösterilir (Şekil 9). Bu öğrenme algoritmalarında, istenilen çıktı değerinin bilinmesine gerek yoktur. Girdi değerleri arasındaki korelasyondan elde edilen çıktı bilgisine göre ağ sınıflandırma kurallarını kendi kendine geliştirmektedir. Ağ daha sonra bağlantı ağırlıklarını aynı özellikleri gösteren örüntüler (patterns) oluşturmak üzere ayarlar (Detienne ve Lewis, 2003; 7). Öğrenme bittikten sonra çıktılarının ne anlama geldiğini gösteren etiketlendirme kullanıcı tarafından yapılır (Öztemel, 2003; 25). Grossberg tarafından geliştirilen ART (Adaptive Resonance Theory) veya Kohonen tarafından geliştirilen SOM (Self Organizing Map) öğrenme kuralı öğretmensiz öğrenmeye örnek olarak verilebilir.

## 3. Destekleyici öğrenme (Reinforcement learning)

Bu öğrenme kuralında da öğrenen sisteme bir öğretmen yardımcı olur. Fakat burada öğretmen olması gereken çıktıyı sisteme vermek yerine, sistemin kendisine

gösterilen girdilere karşılık çıktısını üretmesini bekler ve üretilen çıktının verilen girdiye karşılık iyiliğini değerlendiren bir ölçüte bağlı olarak sinyal üretir (Jain ve Mao, 1996; 35). Sistem öğretmenden gelen bu sinyali dikkate alarak öğrenme sürecini devam ettirir (Şekil 10). Optimizasyon problemlerini çözmek için Hinton ve Sejnowski'nin geliştirdiği Boltzmann kuralı veya GA ile LVQ ağı destekleyici öğrenmeye örnek olarak verilebilirler.




Şekil 10: Destekleyici öğrenme yapısı.

### 2.3.4 Yapay Sinir Ağlarının Eğitimi ve Testi

YSA'nın öğrenme sürecinde, ağı eğitimi ve test edilmesi şeklinde iki aşama bulunmaktadır.

YSA'nın eğitilmesiyle, problem uzayında en az hata verebilecek ağırlık değerlerinin bulunması, yani ağı kendisine gösterilen girdi örneği için beklenen çıktıyı üretmesini sağlayacak ağırlık değerlerinin bulunması amaçlanmaktadır.  $W^*$  en az hatanın olduğu ağırlık vektörü ise, ağı  $W^*$  değerine ulaşması istenmektedir (Şekil 11).



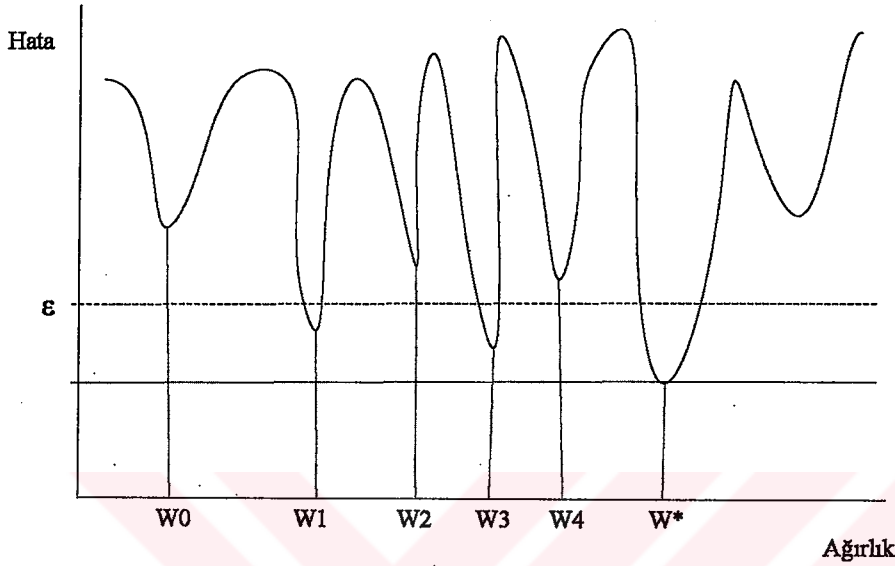
Şekil 11: Öğrenmenin hata uzayındaki gösterimi

$W^*$  problem için hatanın en az olduğu noktadır. Her iterasyonda  $\Delta W$  kadar değişim yaparak hata düzeyinde  $\Delta E$  kadar bir hatanın düşmesi sağlanmaktadır. Problemin hata düzeyi her zaman bu kadar basit ve iki boyutlu olmayabilir. Bazen Şekil 12'deki gibi daha karmaşık bir hata düzeyi söz konusu olabilir. Burada da en iyi çözüm en az hatayı veren  $W^*$  ağırlık vektörüdür fakat pratikte bu değeri yakalamak çoğu zaman mümkün olmamaktadır. Ağ, aslında eğitim sırasında  $W^*$  noktasına ulaşmaya çalışmaktadır, fakat bazen farklı bir çözüme takılıp performansını daha fazla iyileştirememektedir. Bu nedenle ağların performanslarında tolerans değeri ( $\epsilon$ ) kadar hatayı kabul etmek durumunda kalınmaktadır.  $W_0$ ,  $W_2$  ve  $W_4$  kabul edilebilir hata düzeyinin üzerinde olduklarından bu çözümler kabul edilemez çözümlerdir.  $W_1$ ,  $W_3$  kabul edilebilir yani hata düzeyinin altındaki en iyi yerel çözümler,  $W^*$  ise en iyi çözümdür. Örneğin,

- Eğitim setindeki örneklerin problem uzayını yeterince temsil etmemesi,
- Ağ için doğru parametrelerin seçilmemesi,
- Ağırlıkların başlangıç değerlerinin iyi belirlenmemesi,
- Ağın topolojisinin yetersiz seçilmesi



gibi nedenlerden dolayı en iyi çözüme ulaşamamaktadır. YSA birçok probleme bir çözüm bulmakta fakat bunun en iyi olup olmaması konusunda bilgi verememektedir (Öztemel, 2003; 82–85)



Şekil 12: Çok boyutlu hata uzayı

Sinir ağlarının yerel sonuçlara takılıp kalmaması için momentum katsayısı geliştirilmiştir. Momentum katsayısı, bir önceki iterasyondaki değişimin ne kadarının yeni değişim miktarına ekleneceğini belirler (Tan, 1997; 22). Bu katsayının iyi kullanılması, yerel çözümleri kabul edilebilir hata düzeyinin altına çekebilmektedir.

Aslında YSA'nın gerçek amacı, girdi-çıkı örnekleri için genelleme yeteneği olan bir model yaratmaktır. Genelleme, ağın daha önce görmediği, ancak ağın eğitiminde kullanılan örneklerin popülasyonundan gelen girdi-çıkı örneklerini, doğru bir şekilde sınıflandırabilme yeteneğidir. Ağın eğitimi tamamlandıktan sonra öğrenip öğrenmediğini, yani genelleme yeteneğini ölçmek için denemeler yapılır. Bu süreçte ağın öğrenme sırasında görmediği örnekler kullanılır ve test etme sırasında ağın ağırlıkları değiştirilmez. Eğitimde kullanılan örnek setine eğitim seti, test için

kullanılana test seti adı verilmektedir. Genellikle mevcut örneklerin %10'u olarak test seti olarak kullanılmaktadır.

Ağın performansı daha önce görmediği örnekler karşısında ürettiği doğru cevaplar oranı ile ölçülebilir.

$$P = \frac{D}{T} \times 100$$


P: performans oranı

D: test setinden doğru olarak cevaplandırılan örnek sayısı

T: test setinde bulunan toplam örnek sayısı

Ağın yapısının seçimi ve ağın başlangıç koşullarının belirlenmesi, eğitim aşamasında dikkat edilmesi gereken önemli faktörlerdir. Bu faktörler eğitim için gereken süreyi etkilemektedirler. YSA'nın yapısı ve parametrelerini belirleme konusunda belirli kurallar olmadığından, kabul edilebilir bir model belirlemeden önce farklı yapı ve parametre değerlerine sahip çok sayıda yapay sinir ağının oluşturulması gerekebilir. Bu da deneme sürecinin uzamasına neden olabilir. Ağı oluşturan kişinin YSA konusunda tecrübeli olması, çoğu zaman bu süreci hızlandırabilmektedir.

Eğitim aşamasındaki bir diğer önemli konu, eğitim sürecinin ne zaman durdurulacağıdır. Eğer yapay sinir ağı aşırı eğitilirse, ağ girdi-çıkışı ilişkisini ezberleyebilir. Ağ ezberlediğinde, genelleme yeteneği olan bir model yaratmak yerine, yalnızca eğitim setine tam uyan bir model yaratmaktadır. Bu ise genellikle test setindeki verilerde modelin zayıf performans göstermesi ile sonuçlanmaktadır. Örneğin, ağ eğitim setindeki örneklere %100 oranında doğru cevap üretirken, test setindeki performansı %10–20 civarında kalmaktadır.



Kaynak: Lawrence vd., 1996; 21

Şekil 13: Ağın az öğrenmesi ve ezberlemesi

Ağın ezberleme durumu, eğitim verilerinin ve modeldeki parametrelerin sayısı ile ilişkilidir. Eğitim verileri sabit tutulduğunda, modelin çok sayıda parametresi (yani serbestlik derecesi) varsa ağın ezberleme derecesi artmaktadır (Lawrence vd., 1996; 30). Ezberleme durumunda, eğitim setindeki hata çok düşük, fakat test setindeki hata çok yüksek olabilir. Diğer taraftan, eğer ağ yeterince eğitilmezse, en iyi çözüm yerine yerel minimumda takılıp kalabilir. Şekil 13'te (x) işareti ile görülen noktalar eğitim setindeki verilerdir. Bunların arasında kalan eğri, ağ tarafından oluşturulmaktadır. Şekil 13(a)'daki grafikte, ağın eğitim verilerini öğrenemediği, 13(c) de ise ezberlediği görülmektedir. Bu iki model de gerçek hayattaki girdi-çıkı ilişkisini temsil edemeyeceği için kullanılamazlar.

### 2.3.5 Yapay Sinir Ağlarının Öğrenme Algoritmaları

Kullanılan çok sayıda öğrenme algoritması bulunmaktadır. Yapay sinir ağının mimarisine ve karşılaşılan sorunun niteliğine göre farklılık gösteren bu algoritmaların bir kısmı Tablo 4'te bulunmaktadır.

Tablo 4: Öğrenme algoritmaları

Öğrenme metodu	Öğrenme kuralı	Mimarisi	Öğrenme algoritması	Uygulama konusu
Öğretmenli	Hata-düzeltilme	Tek yada Çok katmanlı algılayıcı	Algılayıcı öğrenme algoritmaları Geriye yayma Adaline-Madaline	Örüntü sınıflandırma Fonksiyon yaklaşırma Tahmin, kontrol
	Boltzman	Geridönüşümlü	Boltzman öğrenme algoritması	Örüntü sınıflandırma
	Hebb	Çok katmanlı ileri beslemeli	Doğrusal ayırma analizi	Veri analizi Örüntü sınıflandırma
	Rekabet eden	LVQ ağı	Doğrusal vektör parçalama	Sınıf içi Kategorilere ayırma Veri sıkıştırma
		ART ağı	ARTMap	Örüntü sınıflandırma Sınıf içi Kategorilere ayırma
Öğretmensiz	Hata-düzeltilme	Çok katmanlı ileri beslemeli	Sammon'un projeksiyonu	Veri analizi
	Hebb	İleri beslemeli veya rekabet eden Hopfield ağı	Ana bileşenler analizi Çağırışimli bellek öğrenmesi	Veri analizi Veri sıkıştırma Çağırışimli bellek
	Rekabet eden	LVQ ağı	Vektör parçalama	Kategorilere ayırma Veri sıkıştırma
		Kohonen'in SOM ağları	Kohonen'in SOM ağları	Kategorilere ayırma Veri analizi
		ART ağları	ART1, ART2	Kategorilere ayırma
Destekleyici	Hata-düzeltilme ve Rekabet eden	RBF ağı	RBF öğrenme algoritması	Örüntü sınıflandırma Fonksiyon yaklaşırma Tahmin, kontrol

Kaynak: (Jain ve Mao, 1996; 38)

Finansal tahminleme alanında en yaygın kullanılan öğrenme algoritmaları, Delta Algoritması ve Genelleştirilmiş Delta ya da diğer adıyla Geriye Yayma (Backpropogation) Algoritmasıdır. Bu çalışmada bu iki algoritmaya detaylı olarak yer verilmiştir.

## 1. Delta Algoritması

Delta algoritması ilk olarak Widrow ve Hoff tarafından geliştirilmiş daha çok mühendislik kökenli bir algoritmadır. Bu algoritma en küçük kareler kuralı (Least-Mean-Square Rule-LMS) olarak da bilinmektedir (Rao, 1995; 138).

Delta algoritmasının prensibi: Eğer eğitim sırasında gerçekleşen çıktı ( $\zeta$ ) ile beklenen çıktı ( $B$ ) arasında fark olursa, ağırlıklar bu farkı ( $E=B-\zeta$ ) azaltacak şekilde değiştirilmelidir (Jain ve Mao, 1996; 35).

Bu algoritma, hata karelerinin ortalamasını alarak, bu değer en küçük olduğu çözümü bulmayı amaçlar. Ağ için hata karelerinin ortalaması TH aşağıdaki gibi hesaplanır:

$$TH = \frac{1}{2} \sum_m E_m^2$$

Delta algoritması hataların karesinin en küçük olduğu noktayı bulurken dereceli hata azaltma yöntemini kullanmaktadır (Kröse ve Smagt, 1996; 28). Tek çıktısı ve doğrusal geçiş fonksiyonu olan tek katmanlı bir ağın çıktısı aşağıdaki formül ile bulunur.

$$\zeta = \sum W_i X_i + \theta$$

Hata karelerinin ortalamasının en küçük olduğu noktayı bulmak için ağırlıklar aşağıdaki gibi değiştirilir.  $\lambda$ , öğrenme katsayısıdır

$$W(t+1) = W(t) + \Delta W$$

$$\Delta W = \lambda \cdot E(t) \cdot X(t)$$

Delta algoritmasının en önemli problemi, sabit öğrenme katsayısının ve rassal bileşenin olmasıdır (Lubis, 2001; 21). Daha sonra çok katmanlı algılayıcıların (Genelleştirilmiş Delta Algoritması) bulunması ile bu sorun çözülmüştür. Bir diğer problem ise, ağın her iterasyonda ağırlıklarını değiştirdikçe öğrendiklerini unutması olasılığıdır. Bir girdi seti ağırlıkları artırdıkça diğeri azaltmaktadır (Öztemel, 2003;

68). Bu sorun çoęu zaman ierisinde aęrlıkların bulunması ile özlebilmektedir. Fakat bu, eęitim zamanının uzamasına neden olmaktadır.

## 2. Genelleştirilmiş Delta (Geriye Yayma) Algoritması

Genelleştirilmiş Delta Kuralı iki safhadan oluşur:

- i. safha- ileri doğru hesaplama: Aęın ıktısını hesaplama safhasıdır.
- ii. safha- geriye doğru hesaplama: Aęrlıkları deęiştirme safhasıdır.

### *İleri Doğru Hesaplama*

Bu safhada bilgi işleme eęitim setindeki bir örneęin Girdi katmanından ( $X_1, X_2, \dots$ ) aęa gösterilmesi ile başlar. Girdi katmanında herhangi bir bilgi işleme olmadan gelen girdiler aynen ara katmana gönderilir.

Adım 1: Girdi katmanındaki k. nöronun ıktısı  $C_k^i$  Őu Őekilde belirlenir.

$$C_k^i = X_k$$

Adım 2: Ara katman işlem elemanlarına gelen net girdi ( $NET_j^a$ ) hesaplanır.

$$NET_j^a = \sum_{k=1}^n W_{kj} C_k^i$$

$W_{kj}$ : k. girdi katmanı elemanını j. ara katman elemanına baęlayan baęlantının aęrılık deęeri

Adım 3: j. ara katman elemanının çıktısı ( $C_j^a$ ) hesaplanır.  $C_j^a$ , bu net girdinin Geçiş fonksiyonundan (genellikle sigmoid fonksiyonundan) geçirilmesiyle hesaplanır. Buradaki Geçiş fonksiyonunun türevinin alınabilir olması şarttır. Sigmoid fonksiyonu kullanılması halinde çıktı,

$$C_j^a = \frac{1}{1 + e^{-(NET_j^a + \beta_j^a)}}$$

şeklinde olur.

$\beta_j^a$  : ara katmanda bulunan j. elemana bağlanan eşik değer elemanının ağırlığı

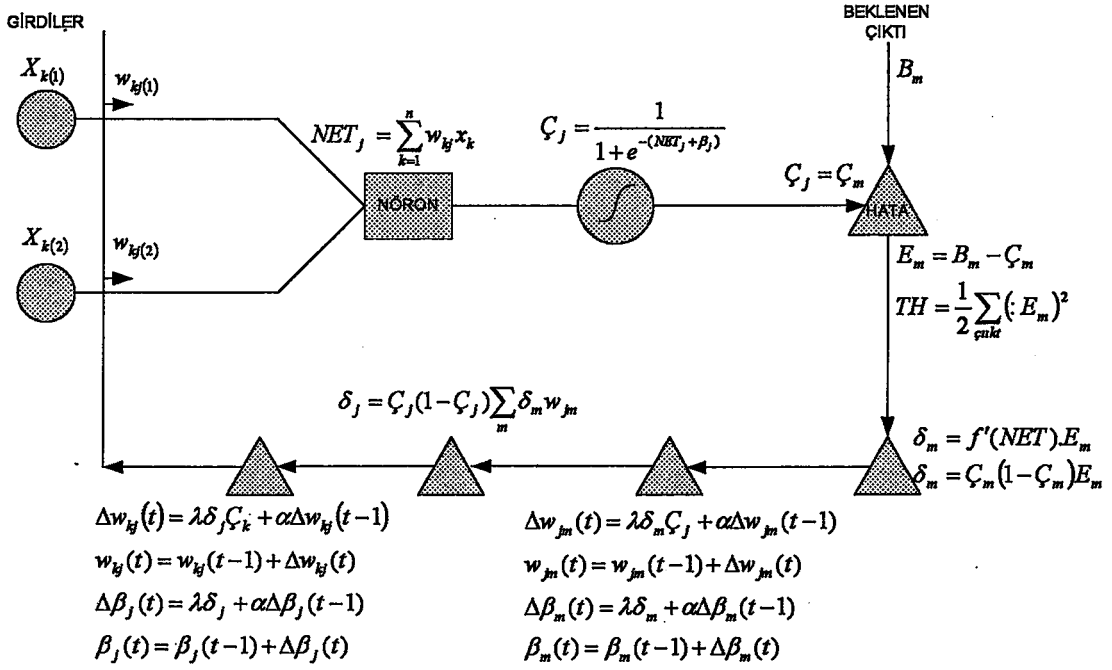
$\beta_j^a$  eşik değeri ünitesinin çıktısı sabit olup 1'e eşittir. Ağırlık değeri ise sigmoid fonksiyonunun oryantasyonunu belirlemek üzere konulmuştur. Eğitim esnasında ağ bu değeri kendisi belirlemektedir.

Adım 4: Çıktı katmanından tüm çıktı değerleri ( $C_1, C_2, \dots$ ) bulununca ağın ileri hesaplama işlemi tamamlanmış olur.

### ***Geriye Doğru Hesaplama (Geriye yayma algoritması)***

Geriye yayma algoritması (Genelleştirilmiş Delta algoritması), çok katmanlı ileri beslemeli ağların eğitiminde en popüler ve en yaygın olarak kullanılmış öğrenme algoritmasıdır. Anlaşılması kolay ve matematiksel olarak ispatlanabilir olması ve aynı zamanda tasarımının ve uygulanmasının kolay olmasından dolayı en çok tercih edilen öğretim algoritmasıdır.

Geriye yayma algoritması, aslında delta algoritmasının bir momentum katsayısı eklenmiş halidir. Momentum katsayısı hataların en küçük olduğu noktayı bulmada doğrultunun ayarlanmasına yardımcı olur. Ayrıca ağın bazı yerel minimumlarda takılarak yanlış çözüme ulaşması, momentum terimi tarafından önlenir.



Şekil 14: Tek bir yapay nöron için hataların geriye yayımı

Burada, ağı sunulan girdi için ağıın ürettiği çıktı, ağıın beklenen çıktıları ( $B_1, B_2, \dots$ ) ile karşılaştırılır. Aralarındaki fark hata olarak kabul edilir ve bu hataların kareleri ortalaması dereceli hata azaltma yöntemi kullanılarak azaltılmaya çalışılır. Bu nedenle geriye doğru hesaplamada bu hata ağıın ağırlık değerlerine dağıtılarak bir sonraki iterasyonda hatanın azaltılması sağlanır (Şekil 14).

Çıktı katmanındaki  $m$ . nöron için oluşan hata ( $E_m$ ),

$$E_m = B_m - C_m$$

olduğundan, çıktı katmanında oluşan toplam hata değeri

$$TH = \frac{1}{2} \sum_m E_m^2$$



olur. ÇKA ağının eğitilmesinde amaç bu hatayı minimuma indirmektir. Bunun için bu hatanın kendisine neden olan işlem elemanlarına dağıtılması gerekmektedir.

Ağın ağırlıklarını değiştirmede iki durum söz konusudur:

- i. Ara katman ile çıktı katmanı arasındaki ağırlıkların değiştirilmesi
- ii. Ara katmanlar arası veya ara katman girdi katmanı arasındaki ağırlıkların değiştirilmesi

1. Ara katman ile çıktı katmanı arasındaki ağırlıkların değiştirilmesi

Herhangi bir t zamanında (t. iterasyonda), ara katmandaki j. nöronu çıktı katmanındaki m. nörona bağlayan bağlantının değişim miktarı ( $\Delta A^a$ ), aşağıdaki formül ile hesaplanır.

$$\Delta w_{jm}^a(t) = \lambda \delta_m C_j^a + \alpha \Delta w_{jm}^a(t-1)$$

$\lambda$ : öğrenme katsayısıdır. Ağırlıkların değişim miktarını ifade eder.

$\alpha$ : momentum katsayısıdır. Ağın öğrenmesi sırasında yerel bir optimum noktaya takılıp kalmaması için ağırlık değişim değerinin belirli bir oranda bir sonraki değişime eklenmesini sağlar.

$\delta_m$ : m. çıktı ünitesinin hatasıdır.

$\delta_m = f'(NET) \cdot E_m$  ile hesaplanır.  $f'(NET)$  Geçiş fonksiyonunun türevidir. Sigmoid fonksiyon kullanılması durumunda  $\delta_m = C_m(1 - C_m) \cdot E_m$  olur.

Değişim miktarı hesaplandıktan sonra ağırlıkların t. iterasyondaki yeni değerleri,

$$w_{jm}^a(t) = w_{jm}^a(t-1) + \Delta w_{jm}^a(t)$$

şeklinde olur.

Benzer şekilde, eşik değer ünitesinin de ağırlıklarını değiştirmek gerekmektedir. Çıktı katmanındaki nöronların eşik değer ağırlıklarının ( $\beta^e$ ) değişim miktarı (bu ünitenin çıktısının sabit ve 1 olması nedeniyle),

$$\Delta\beta_m^e(t) = \lambda\delta_m + \alpha\Delta\beta_m^e(t-1)$$

olur. Buna göre, eşik değerin t. iterasyondaki ağırlığının yeni değeri, aşağıdaki gibi olur.

$$\beta_m^e(t) = \beta_m^e(t-1) + \Delta\beta_m^e(t)$$

## 2. Ara katmanlar arası veya ara katman girdi katmanı arasındaki ağırlıkların değiştirilmesi

Ara katman ile çıktı katmanı arasındaki ağırlıkların değişiminde her ağırlık için sadece çıktı katmanındaki bir nöronun hatası dikkate alınmaktadır. Bu hataların oluşmasında girdi katmanı ve ara katman (varsa iki ara katman) arasındaki ağırlıkların payı vardır. çünkü en son ara katmana gelen bütün bilgiler kendisinden önceki katman(lar)dan gelmektedir. B nedenle, girdi katmanı ile ara katman arasındaki ağırlıkların değiştirilmesinde çıktı katmanındaki işlem elemanlarının hepsinin hatasından payını alması gerekir.

Bu ağırlıklardaki değişim miktarı ( $\Delta w^i$ ),

$$\Delta w_{kj}^i(t) = \lambda\delta_j^a C_k^i + \alpha\Delta w_{kj}^i(t-1)$$

ile bulunur.  $\delta_j^a$ : hata terimidir ve  $\delta_j^a = f'(NET) \sum_m \delta_m w_{jm}^a$  formülü ile bulunur. Geçiş fonksiyonu sigmoid olduğunda, hata terimi  $\delta_j^a = C_j^a(1-C_j^a) \sum_m \delta_m w_{jm}^a$  formülü ile hesaplanır.

Ağırlıkların yeni değerleri,

$$w_{kj}^i(t) = w_{kj}^i(t-1) + \Delta w_{kj}^i(t)$$

ve ara katman eşik değer ağırlıkları için değişim miktarı ve t. iterasyonda yeni değerleri,

$$\Delta \beta_j^a(t) = \lambda \delta_j^a + \alpha \Delta \beta_j^a(t-1)$$

$$\beta_j^a(t) = \beta_j^a(t-1) + \Delta \beta_j^a(t)$$

şeklinde olur.

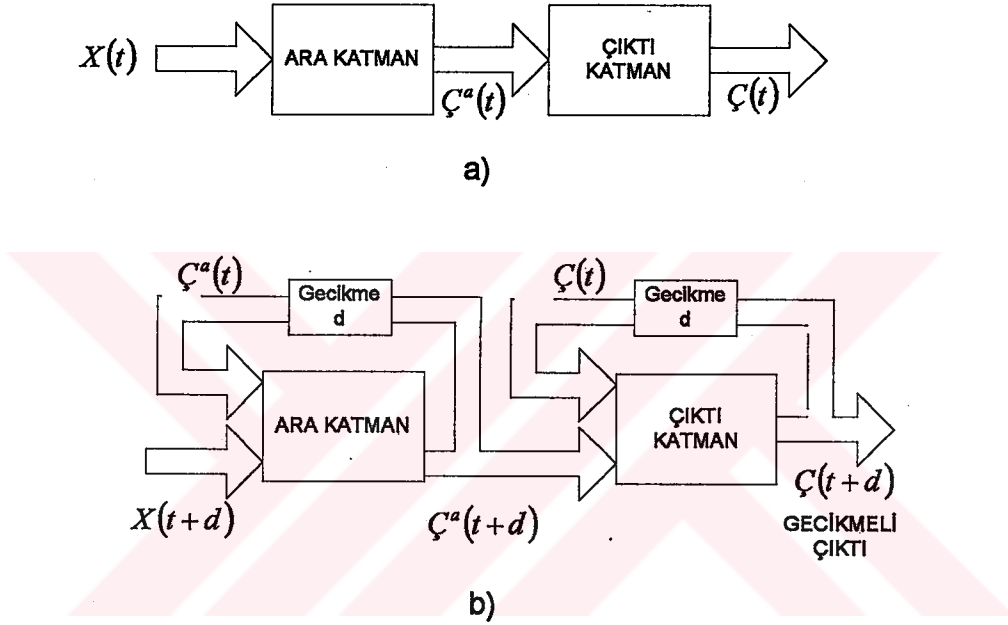
### 2.3.6 Yapay Sinir Ağlarının Mimari Yapısı

YSA, genel olarak birbirleri ile bağlantılı yapay nöronlardan oluşurlar. Her bir nöron arasındaki bağlantıların yapısı, ağın mimarisini belirler. Bir ağın mimarisinden söz edildiğinde, bağlantıların topolojik yapısı, ağdaki katman sayısı ve her bir katman içindeki nöron sayısı kastedilmektedir.

Farklı bağlantı tipleri farklı ağ davranışlarına yol açmaktadır. Mimari farklılıklar modelin doğrudan performansını etkileyen bir faktördür. Bu nedenle YSA'nın tasarım aşamasında uygulamaya en elverişli olan yapının seçilmesi gerekir. YSA bağlantı yapılarına göre, ileri beslemeli (feedforward) ve geri beslemeli (feedback) ağlar olmak üzere iki gruba ayrılmaktadır:

## İleri Beslemeli Ağlar

İleri beslemeli ağlarda nöronlar genellikle katmanlara ayrılmışlardır. Girdiler, girdi katmanından çıktı katmanına doğru tek yönlü bağlantılarla iletilir. Nöronların bir katmandan diğer bir katmana bağlantıları mevcuttur, fakat aynı katman içerisinde bağlantıları bulunmaz. Bu nedenle, ileri beslemeli ağlar, statik bir yapıya sahiplerdir, yani bir girdinin ardışık değerlerinden ziyade, yalnızca bir çıktı seti üretirler. Bir girdiye verdikleri cevabın ağın önceki durumundan bağımsız olması nedeniyle bellekleri bulunmamaktadır. Şekil 15 (a)'da ileri beslemeli ağ yapısı gösterilmiştir.

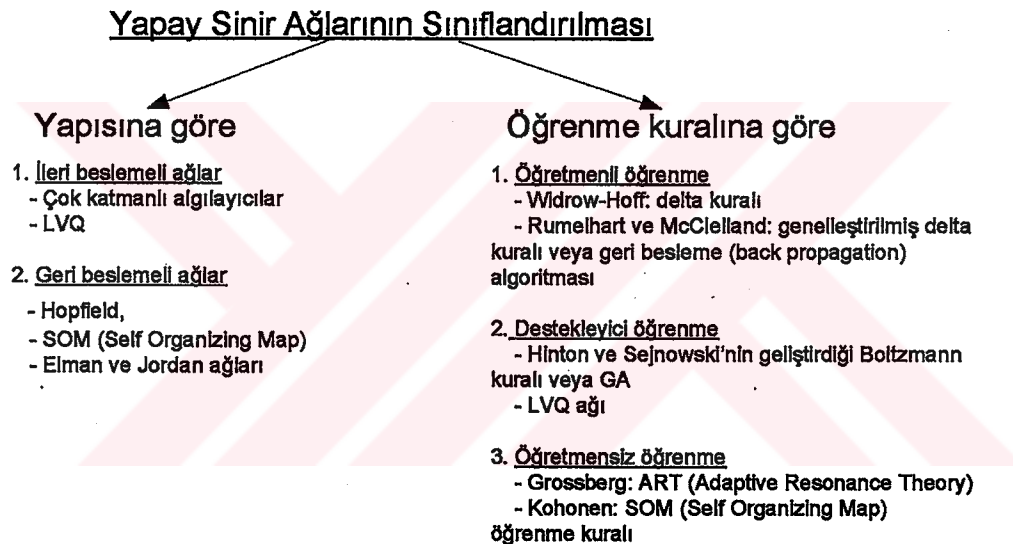


Şekil 15: İleri beslemeli ve geri beslemeli ağların temel yapısı

En yaygın uygulama alanı örüntü tanımadır. Bu nedenle sınıflandırma problemlerinde başarıyla uygulanabilmektedir (Reeves, 1995; 197). Çözüm üretmek için yalnızca tek bir geçiş gerektirdiğinden ileri beslemeli ağlar, geri beslemeli ağlardan daha hızlıdır (Tan, 1997; 30).

## Geri Beslemeli Ağlar

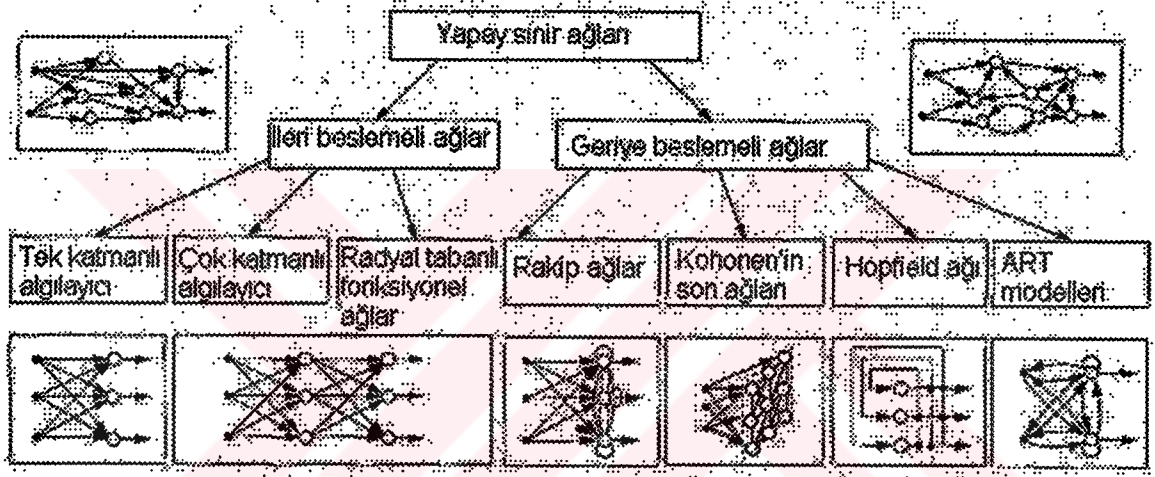
Bir geri beslemeli sinir ağlarında, çıktı ve ara katmanlardaki çıktılar, girdi elemanlarına veya önceki ara katmanlara geri beslenmektedir. Böylece, girdiler hem ileri yönde hem de geri yönde iletilmektedir. Şekil 15 (b)'de geri beslemeli ağ yapısı görülmektedir. Bu tür sinir ağlarının dinamik hafızaları vardır ve belirli bir andaki çıktı hem o andaki hem de önceki girdileri yansıtır. Bu özellikleri ile, geri beslemeli ağlar özellikle tahmin ve optimizasyon uygulamaları için uygun olmaktadır. Bu ağlar çeşitli tipteki zaman-serilerinin tahmininde oldukça başarılı bir şekilde uygulanabilmektedirler (Kaastra ve Boyd, 1996; 218).



Şekil 16: Yapay sinir ağlarının sınıflandırılması

Yazında çok sayıda yapay sinir ağı bulunmaktadır. YSA bağlantı yapılarına göre sınıflandırılmalarının yanında, her farklı ağ mimarisine uygun bir öğrenme algoritmasına ihtiyaç duyulmaktadır. Şekil 16'da uygulamalarda en yaygın olarak kullanılan bazı ağlar için, hem yapılarına hem de öğrenme algoritmalarına göre sınıflandırmaları verilmiştir. Şekil 17'de ise, bağlantı yapılarına göre çeşitli ağların topolojik yapıları gösterilmiştir.

Yapay sinir ağının tasarım aşamasında mimarisinin seçilmesi büyük ölçüde ağda kullanılması gereken öğrenme algoritmasına bağlıdır. Öğrenme algoritmasının belirlenmesiyle bu algoritmanın gerektirdiği mimaride seçilmiş olmaktadır. Daha önce Tablo 4’te ve Şekil 16’da öğrenme algoritmalarına göre ağlar sınıflandırılmıştır. Örneğin, geri yayılım algoritması ileri beslemeli ağ mimarisi gerektirmektedir. Tablo 5’te ise, çeşitli yapay sinir ağları, bunların en iyi performans gösterdikleri uygulama alanları ve kuvvetli-zayıf yönleri özetlenmiştir. Örneğin, en eski sinir ağı modeli olan basit algılayıcı, basılı yazı karakterlerini tanımda üstün performans gösterirken, karmaşık örüntüleri tanıma konusunda zayıf kalmaktadır.



(Kaynak: Jain ve Mao, 1996; 35)

Şekil 17: Bağlantı yapılarına göre çeşitli ağların mimarileri

Tablo 5: Çeşitli sinir ağı modellerinin kuvvetli ve zayıf yönleri

Sinir modeli	Temel uygulamalar	Kuvvetli yönler	Zayıf yönler
Kohonen (LVQ)	Eksik veri ve resim parçalarının tamamlanması, sınıflandırma	Geniş çaplı uygulama	Öğrenme yok, ağırlıkların verilmesi gerekli
Hopfield	Eksik veri ve resim parçalarının tamamlanması,	Geleneksel optimizasyon algoritmaları ile çözülmesi mümkün olmayan karmaşık problemleri çözebilmesi	Ağın minimum hata düzeyine ulaşmasının her durumda mümkün olmaması (durağan duruma geçememesi)
Algılayıcı (perseptron)	Basılı yazı karakterlerinin tanınması	En eski sinir ağı	Karmaşık örüntüleri tanıyamama, değişikliklere karşı duyarlılık (her iterasyonda ağırlıkların değiştirdikçe öğrendiklerini unutması)
Çok katmanlı algılayıcı/ Delta kuralı	Örüntü (desen) tanıma	Basit bir ağ, basit algılayıcının genelleştirilmiş hali	Karmaşık örüntülerin tanınmaması
Geriye yayma	Geniş uygulama alanı: konuşma sentezi ve analizi, kredi başvurusu değerlendirme	En popüler ağ, iyi çalışır, öğrenmesi de kolaydır	Çok fazla örnekle desteklenen öğretmenli öğrenme
Boltzman makinesi	Örüntü tanıma (radar, sonar)	Gürültü fonksiyonunu en küçük enerji seviyesine ulaşmak için kullanan basit bir ağ	Uzun öğrenme süresi
Counter propagation (Kohonen-Grosberg) ağı	Görüntü sıkıştırma, istatistiksel analiz, şekil tanıma ve kredi notlama	Çok katmanlı algılayıcı, fakat geriye yayma algoritmasından daha hızlı, eksik ve kısmen yanlış verilerle çalışabilmesi	Çok sayıda yapay nöron ve bağlantı
SOM (Kohonen) ağı	Geometrik bir alanı bir başkasına eşleştirme	Birçok algoritmik tekniğe daha iyi performans	Yoğun eğitim gereksinimi, uzun öğrenme süresi
Neocognitron ağı	El yazısı karakterlerin tanınması,	İnsan görme sistemini modelleyen, karmaşık örüntüleri algılayabilen ileri düzey bir ağ	Çok sayıda yapay nöron ve bağlantı

Kaynak: Bayraktaroğlu, 1996; 4 (*Circuit Level Simulation Based Training Algorithms For Analog Neural Networks* adlı doktora tezinden değiştirilerek alınmıştır)

## 2.4 Yapay Sinir Ağları Teknolojisinin Değerlendirilmesi

### 2.4.1 Yapay Sinir Ağlarının Güçlü Yanları

Pek çok istatistikçi yapay sinir ağlarının istatistiksel modellerin özel durumları olduğunu ve istatistiksel modellere uygulanan kısıtlamaların yapay sinir ağlarına da uygulanması gerektiğini savunmaktadır (Tan, 1997; 19). Bu henüz tartışılan bir durum olmakla birlikte, birçok araştırmacı yapay sinir ağlarının bilinen istatistiksel tekniklere kıyasla daha iyi performans gösterdiğini yaptıkları çalışmalarla kanıtlamıştır. Yapay sinir ağları, oluşturulması ve eğitimi oldukça basit ve hacmi büyük gürültülü verilerle baş etmesi kolay olan bir modeldir. Her ne kadar ağı oluştururken, verilerin seçimi ve ağa gösterimden önce ve sonra verilere bazı işlemlerin uygulanması fazla vakit alsa da, yapay sinir ağları, karmaşık ilişkileri hızlı ve yüksek doğruluk derecesi ile analiz etme yeteneği ile tercih sebebi olabilecek bir araçtır. YSA'nın doğrusal olmayan problemlere çözüm üretebilmesi, onları özellikle çevrenin potansiyel olarak değişken ve dinamik olduğu finans gibi alanlarda başarılı kılmaktadır.

YSA'nın diğer yöntemlere göre üstünlüğünü sağlayan temel özellikleri şunlardır:

#### ***Doğrusal Olmama***

YSA'nın temel işlem elemanı olan hücre doğrusal değildir. Dolayısıyla hücrelerin birleşmesinden meydana gelen yapay sinir ağı da doğrusal değildir ve bu özellik tüm ağa yayılmış durumdadır. Bu özelliği ile YSA, doğrusal olmayan karmaşık ilişkileri hızlı ve yüksek doğruluk derecesi ile analiz edip, bunları başarılı bir şekilde modelleyebilmektedir.



## ***Öğrenme***

Aslında öğrenmeden kasıt, ilgili problemdeki girdi-çıkıtı ilişkisini en iyi tanımlayacak optimum ağırlıkların bulunmasıdır. Bunun için girdi-çıkıtı ilişkisinin fonksiyonel biçimine ilişkin ön bir bilgiye gereksinim duymamaktadır. Altında yatan populasyon hakkında varsayımlar yapmak yerine, YSA girdi-çıkıtı arasındaki ilişkileri ortaya çıkarmak için verileri kullanır. Sonuç olarak, değişkenler arasındaki ilişki varsayılan bir modele uymadığında, yapay sinir ağları ile daha iyi sonuçlar elde edileceği beklenmektedir.

## ***Genelleme***

YSA'nın en önemli özelliklerinden biri de bilgiyi depolamalarıdır. Nöral hesaplamalarda bilgi ağırlıklar üzerine dağıtılmıştır. Bağlantıların ağırlıkları, ağız hafıza birimidir. Bu ağırlıklar ağız o andaki sahip olduğu bilgiyi veya uygulanan örneklerden öğrenmiş olduğu davranışı verir. Bu bilgiler, ağızdaki birçok ağırlıklar üzerine (hafıza birimine) dağıtılır. Buna dağıtılmış birleşik hafıza denir.

YSA, ilgilendiği problemi öğrendikten sonra, eğitim sırasında karşılaşmadığı test örnekleri için de uygun tepkiyi üretme kabiliyetine sahiptir. Örneğin, karakter tanıma amacıyla eğitilmiş bir yapay sinir ağı, bozuk karakterli girdilerde de doğru karakteri verir. Dağıtılmış birleşik hafıza özelliği sayesinde, eğitilmiş ağız girdi verisinin sadece bir kısmı verilse bile, ağız hafızadan bu girdiye en yakını seçerek tam bir girdi verisi alıyormuş gibi kabul eder ve buna uygun bir çıkıtı değeri üretir. Yapay sinir ağına, veriler eksik, bozuk veya daha önce hiç karşılaşmadığı şekilde verilse bile, ağız kabul edilebilir en uygun çıkıtıyı üretecektir. Bu özellik ağız genelleme özelliğidir.

## ***Uyarlanabilirlik***

YSA ağırlıkları, uygulanan probleme göre değiştirilir. Yani, belirli bir problemi çözmek amacıyla eğitilen YSA, problemdeki değişimlere göre tekrar eğitilebilir. Değişimler devamlı ise gerçek zamanda da eğitime devam edilebilir. Bu

özelliđi ile YSA, uyarlamalı örnek tanıma, işaret işleme, sistem tanımlama ve denetim gibi alanlarda etkin olarak kullanılır.

### ***Hata toleransı***

YSA, çok sayıda işlemci elemanların bağlantısı paralel dağılmış bir yapıya sahiptir ve ađın sahip olduđu bilgi, ađdaki tüm bağlantılara dağılmıştır. Giriş veri setinde bulunabilecek herhangi bir gürültü, bütün ađırlıklar üzerine dağıtıldığından dolayı, gürültü etkisi tolere edilebilir. Geleneksel yöntemlere göre hatayı tolere etme yetenekleri daha fazladır.

### ***Paralel işlem yapma***

YSA, paralel yapısı nedeniyle uygulama sürecinde hızlı çözümler üretebilirler. Paralel yapı, büyük ölçekli entegre devre teknolojisi ile gerçekleştirilmektedir. Bu özellik, YSA'nın hızlı bilgi işleme yeteneđini ve örnek tanıma, işaret işleme, sistem kimliklendirme ve denetim gibi gerçek zaman uygulamalarında kullanımını artırır.

### ***Uygulama kolaylıđı***

İstatistiksel yöntemlerin maruz kaldıđı kısıtlamalar konusunda güçlü istatistik bilgisi olmadan, çođu araştırmacı, bunları göz ardı ederek analizler yapmaya kalkışmaktadır. Bunun sonucunda ise, sađlıksız sonuçlarla yorumlar yapılmaktadır. YSA ile bir problemi oluşturmak klasik istatistiksel yöntemlerle modelleme yapmaktan daha kolaydır. Çünkü araştırmacılar öğrenme algoritmalarını tam anlamadan bile, YSA paket programlarını klasik istatistiksel programlardan daha kolay ve başarılı bir şekilde kullanabilmektedirler. Bu da çeşitli alanlardaki araştırmacıların YSA'na kolaylıkla ulaşabilmesini sađlamaktadır. YSA araştırmacıları istatistiksel kurallara gerek kalmadan, tecrübe ile YSA'nı öğrenebilmektedirler.

## 2.4.2 Yapay Sinir Ağlarının Zayıf Yönleri

### *Yapay sinir ağlarının donanım bağımlı çalışmaları*

Ağların temel var oluş nedenlerinden birisi paralel işlemciler üzerinde çalışabilmeleridir. Bunun için, paralel çalışabilen işlemcilere ihtiyaç vardır. Günümüzde makinelerin çoğu seri şekilde çalışabilmekte ve tek bir bilgiyi işleyebilmektedir. Paralel işlemleri bu makinelerde yapmak zaman kaybına yol açmaktadır. Bir ağın nasıl oluşturulması gerektiğini belirleyecek kuralların olmaması da bir başka sorundur. Çünkü her problem farklı sayıda işlemci gerektirebilir.

### *Uygun çözüme ulaşamama*

Eğer problem için uygun bir ağ oluşturulamazsa, çözümü olan bir problemin çözülememesi veya performansı düşük çözümlerin elde edilmesi söz konusudur. Bulunan çözümün en iyi çözüm olduğu da garanti değildir. Yani, YSA kabul edilebilir çözümler üretebilmekte, fakat optimum çözümü garanti edememektedir.

### *Ağın parametrelerinin kullanıcının tecrübesine göre belirlenmesi*

Bazı ağlarda ağın öğrenme katsayısı, her katmanda olması gereken nöron sayısı, katman sayısı gibi parametre değerlerinin belirlenmesinde bir kural bulunmaması, iyi çözümler bulmayı zor durumda bırakabilmektedir. Kullanıcının tecrübesine bağlı olarak parametrelerin belirlenmesi durumunda her problem için ayrı faktörler dikkate alınmaktadır, dolayısıyla bu değerler için bir standart oluşturulamamaktadır. Bir standardın olmayışı, aynı zamanda ağın mimarisinin oluşturulması için bazen çok fazla zaman harcamayı gerektirmektedir. İyi bir yapay sinir ağı mimarisi bulmak, en az ağa gösterilen verilerin öncül ve ardıl işlemleri kadar zaman alıcı bir süreçtir.

### ***Problemin ađa gsterim Őeklinin kullanıcının tecrbesine gre belirlenmesi***

YSA sadece nmerik bilgilerle alıřabildiđinden, problemin nmerik gsterime dnřtrlmesi gerekir. Bu kullanıcının becerisine bađlıdır ve uygun bir gsterim mekanizmasının kurulamamıř olması problemin zmn engelleyebilir ya da dřk performanslı bir đrenme elde edilebilir. Problemin nmerik gsterimi mmkn olsa bile, bunun ađa gsteriliř Őekli de bařarımı etkiler. rneđin, bir olay hem kesikli hem de srekli deđerler ile gsterilebilir. Hangisinin daha bařarılı bir đrenme gerekleřtireceđi ise bilinmemektedir. Bu konuda kullanıcının tecrbesi yetmeyebilir. Bu gnmzde birok olayın YSA ile zlememesinin en nemli nedenlerinden birisidir.

### ***Optimum netice veren bir mekanizmanın bulunmayıřı***

Ađın eđitiminin ne zaman bitirileceđine karar vermek iin geliřtirilmiř bir yntem yoktur. Ađın rnekler zerindeki hatasının belirli bir deđerin altına indirilmesi eđitimin tamamlanması iin yeterli grlmektedir. Fakat neticede optimum đrenmenin gerekleřtiđi garanti deđildir.

### ***Ađın davranıřlarının aıklanamaması***

YSA'nın en byk zayıflıđı yarattıkları modelleri aıklayamamalarıdır. Bu konuda hala arařtırmalar srmektedir. YSA'nın, tahmin edilen ađ ađırlıklarını yorumlayamamaktadır. Bir probleme zm retildiđi zaman bunun nasıl ve neden retildiđi konusunda bir bilgi bulmak mmkn deđildir (Kara kutu problemi). Bu ise, ađın sonucuna olan gveni azaltmaktadır.

### 3 İLK HALKA ARZLAR

#### 3.1 Giriş

Bir hisse senedinin ilk halka arzı (İHA), bir şirketin hisse senedini ilk kez halka satması veya bir başka deyişle, bir şirketin sermayesinin bir bölümünü, bedelini ödemeye hazır olan kişilere satması demektir. Şirketler halka açılarak mülkiyetin tabana yayılmasını sağlarlar ve böylece ek sermaye edinirler. Halka açılma kararı ile birlikte yasal prosedürler yerine getirilmeye başlanır. İHA sürecinin en karmaşık ve zor fakat belki de en önemli kısmı, şirket ya da aracı kurum tarafından bir hisse senedinin halka arz fiyatının belirlenmesidir. İHA fiyatı, aslında hisse senedini ihraç eden şirketin değerlendirilmesi ile belirlenmektedir. Bir şirketin değeri, somut ve soyut varlıklarının gelecekteki nakit akışlarının bugünkü değeridir (Jain ve Nag, 1995; 285). Bu değeri belirlemek,

- Şirketin geçmişteki ve gelecekteki (tahmini) finansal durumu,
- Yönetim takımının tecrübesi ve kalitesi,
- Piyasa koşulları,
- Bugün ve gelecekte şirketin rekabet gücü,
- İçinde bulunduğu endüstrinin yapısı,
- Yatırımcıların talebi

gibi çok sayıda bağımsız ve birbirleri ile ilişkileri belli olmayan değişkenlere bağlıdır ve bunların derinlemesine analizini gerektirir (McCarthy, 1999; 52). Bu analizler sonrasında, bir şirketin hissesinin İHA fiyatı belirlenmektedir. Fakat tüm faktörler kusurlu ve eksik bilgilere bağlı ve subjektif olarak değerlendirildiğinden, İHA fiyatı konusunda hisse senedini ihraç eden şirket ile aracı kurum arasında uzlaşma sağlanması zor olmaktadır. Çünkü iki tarafın beklentileri birbirine zıt düşmektedir. Hisse senedini ihraç eden şirket, İHA hasılatını maksimize etmek için mümkün olan en yüksek fiyatı güvenceye almaya çalışır Aracı kurumlar ise, daha temkinli olmaya yatkındırlar. Hem şirketin hem de iyi bir gelir sağlamak isteyen yatırımcıların beklentilerini karşılayacak adil bir fiyat bulmaya çalışırlar. Eğer yatırımcıların talebini yüksek tahmin ederlerse satılmamış bir miktar hisse ile karşı karşıya kalabilirler. Bu nedenle, yatırımcıları hisse almaya özendirmek ve ihracı müşterilere

pazarlama maliyetini düşürmek için, ilk halka açılmada düşük fiyatlama çalışırlar. Şirket ve aracı kurum arasındaki uzun tartışmalar sonrasında, bir İHA fiyatı belirlenir.

Hissenin fiyatı belirlenince, şirket, tüm arz edilen hisse senetlerini sabit fiyatla halka satmayı taahhüt eder. Şirketin piyasa fiyatı (değeri), İHA'ın ikincil piyasada işlem görmesiyle ortaya çıkar. Eğer hissenin piyasaya çıktıktan sonraki fiyatı, İHA fiyatının önemli ölçüde altında (üstünde) olursa, bu durumda düşük fiyatlama (aşırı fiyatlama) gerçekleşmiş olur. Hisse senedinin gerçek değerinin altında ya da üstünde fiyatlanması, İHA sürecinde yer alan taraflardan bazılarını dezavantajlı duruma düşürebilir. Bu durumda, ihraç eden kurum ve aracı kurumların, İHA'ları, gözlenemeyen İHA sonrası piyasa fiyatına mümkün olduğunca yakın fiyatlamaları önem kazanmaktadır.

Yeni hisseleri gerçekçi bir şekilde fiyatlama ihtiyacının olmasına rağmen, halka ilk kez arz edilen hisse senetlerinin performansları ile ilgili yapılan ampirik çalışmalar, genellikle bu ihraçların önemli ölçüde düşük fiyatlandırıldığını göstermektedir. Tablo 6'da görüldüğü gibi, çeşitli ülkelerde yapılan pek çok çalışma, İHA'ların ortalama olarak düşük fiyatlama oranının %15'i geçtiğini belirtmektedir.

Tablo 6: Düşük fiyatlama ile ilgili çalışmalar

Ülke	Çalışmayı yapan(lar)	Çalışmanın yapıldığı dönem	İlk gün getirilerin ortalaması
Çin	Chi ve Padgett, 2001	1996-2000	%129.16
ABD	Loughran ve Ritter, 2002	1990-1998 1999-2000 (internet krizi)	%15 %65
İsveç	Loughran vd. 1994	1970-1991	%38.2
Avustralya	Dimovski ve Brooks, 2004	1994-1999	%25.6
Kanada	Kooli ve Suret, 2002	1991-1998	%22.57
İngiltere	Levis, 1993 Shiwakoti vd., 2004	1980-1988 1989-2000	%14.3 %5.64
Türkiye	Kıymaz, 2000 Durukan, 2006	1990-1996 1994-2003	%13.1 %7.05

Bu bölümde, Türkiye'de halka açılma, halka açılmanın nedenleri, şirket açısından yarar ve sakıncaları, halka arz süreci, halka arz yöntemleri, halka arza aracılık açıklanmıştır. Ayrıca, hisse senetlerinin halka ilk arzda düşük fiyatlandırılması ile ilgili hipotezlere yer verilmiştir.

### 3.2 Türkiye'de Halka Açılma

Bir ülkenin ekonomik gelişmesinde rol oynayan faktörlerden biri, fon fazlası olanlar ile fon açığı olanları bir araya getiren finansal pazarların belirli bir etkinlik kazanmış olmasıdır. Türkiye'de sermaye piyasası konusundaki ilk ciddi adım 30 Temmuz 1982 tarihinde 2499 sayılı Sermaye Piyasası Kanunu'nun çıkarılması ile atılmıştır. Sermaye Piyasası Kanunu, esas olarak birinci el piyasaları düzenlemiştir. Ardından bunu tamamlamak üzere ikinci el piyasaları düzenlemek amacıyla 1983 yılında Menkul Kıymetler Borsaları Hakkında 91 Sayılı Kanun Hükmünde Kararname çıkarılarak borsanın kuruluş, işleyiş ve örgütlenmesi ile ilgili genel düzenlemeler yapılmış ve borsanın gözetim ve denetimi Sermaye Piyasası Kurulu'na\* verilmiştir. 1984 yılında çıkarılan Menkul Kıymetler Borsalarının Kuruluş ve Çalışma Esasları Hakkında Yönetmelik ile daha ayrıntılı düzenlemeler yapılmıştır. 1985 yılında ise İstanbul Menkul Kıymetler Borsası\* Yönetmeliği çıkarılarak 1986 yılından itibaren Türkiye'de yasal açıdan yapılandırılan organize menkul kıymet borsası faaliyete geçmiştir.

Özellikle 1990'lı yıllar Türk sermaye piyasası açısından önemli gelişmelerin gözlemlendiği yıllar olmuştur. Bu yıllarda hem finansal araç çeşidinde artış olmuş hem de şahıs ya da aile şirketi ünvanı taşıyan şirketler, daha önce oto finansman yoluyla ya da yabancı kaynak (banka kredileri ve ticari krediler) kullanarak karşıladıkları finansman ihtiyaçlarını halka açılarak karşılamaya başlamışlardır.

Türk Ticaret Kanununda tanımı yapılmış olmasına rağmen, hisse senedi bir şirketin sermayesinin bir bölümünü temsil eden kıymetli evrak olarak tanımlanabilir.

---

\* Bu çalışmada Sermaye Piyasası Kurulu, SPK kısaltması ile anılacaktır.

† Bu çalışmada İstanbul Menkul Kıymetler Borsası, İMKB kısaltması ile anılacaktır.

Halka açılma ise, bir şirketin hisse senetlerinin bedelini ödemeye hazır olan kişilere satılmasıdır.

Sermaye Piyasası Kanunu'na göre halka arz; sermaye piyasası araçlarının satın alınması için her türlü yoldan halka çağrıda bulunulmasını, halkın bir anonim ortaklığa katılmaya veya kurucu olmaya davet edilmesini, hisse senetlerinin borsalar veya teşkilatlanmış diğer piyasalarda devamlı işlem görmesini ve Sermaye Piyasası Kanunu'na göre halka açık anonim ortaklıkların sermaye artırımları dolayısıyla paylarının veya hisse senetlerinin satışını ifade eder (SPK, 2499.madde 3/C). Türk Ticaret Kanunu'na göre anonim ortaklık, bir ünvana sahip, esas sermayesi belirli ve hisselerle bölünmüş ortaklık olarak tanımlanmaktadır. Halka açık anonim ortaklık ise, hisse senetleri halka arz edilmiş olan veya halka arz edilmiş sayılan anonim ortaklıktır. Anonim ortaklıklar hisse senedi çıkararak toplumda birikmiş, ancak atıl kalmış ya da verimsiz kullanılan tasarrufları toplarlar ve daha verimli alanlara kanalize ederek artı değerler yaratırlar (Yükücü vd., 1999; 985). Pay sahibi sayısı 100'ü aşan anonim ortaklıkların hisse senetleri, halka arz olunmuş sayılmakta ve halka açık anonim ortaklık hükümlerine tabi olmaktadır. Halka açık anonim şirketler, Türk Ticaret Kanunu ve Sermaye Piyasası Kanunu'na tümüyle tabi olup, SPK ve İMKB'nin sürekli denetimine girmektedirler (Sorularla Borsa, 2003; 3-5).

Anonim şirketlerde ortaklık sıfatı hisseye göre belirlenir. Yatırımcı hisse senedine sahip olduğunda, her türlü ortaklık hakkından yararlanma imkânı elde etmektedir. Hisse senedine sahip olan kişilerin elde edeceği haklar şunlardır (Bozer, ve Göle,1996):

- Şirket kârından pay alma hakkı,
- Şirket yönetimine katılma hakkı,
- Oy kullanma hakkı,
- Rüçhan hakkı,
- Tasfiyeden pay alma hakkı,
- Şirketin faaliyetleri hakkında bilgi edinme hakkı.



Hisse senetleri sahiplerine sağlanan yönetime katılma, oy kullanma ve şirketin faaliyetleri hakkında bilgi edinme hakları ortaklık haklarıdır. Bunlardan en önemlisi, yönetime katılma hakkıdır. Bu hak, şirket yönetim kurulunu seçmek ve hatta bu kurula seçilmeyi sağlamaktadır. Ancak yönetim hakkına, şirket sermayesinin %51'ini elinde bulunduran ya da bulunduranlar sahip olabilmektedir. Fakat sermayenin tabana yayılması halinde, yönetim hakkı çoğu örneklerde ilginç bir görünüm almakta ve bazı şirketlerde %10'luk oy ile yönetimin ele geçirilebildiği görülmektedir. Gerek ana sözleşmeye konulacak özel hükümlerle, gerek bazı hallerde yasal müdahalelerle azınlık paylarının yönetimde seslerini duyurabilmeleri sağlanabilmektedir (Bozer ve Göle, 1996). Örneğin, hisse sahibi istediği anda şirketin faaliyetleri hakkında bilgi edinme, faaliyetleri denetleme ve onaylamadığı bazı kararlar için iptal davası açabilme haklarına sahiptir.

Kar payı alma hakkı, rüçhan hakkı ve tasfiyeden pay alma hakkı, hisse senetlerinin sahibine sağladığı mali haklardır. Bir anonim ortaklıkta mevcut ortaklar, yalnızca kayıtlı sermaye üzerinde değil, ortaklığın tüm öz varlığı üzerinde hak sahibidirler. Rüçhan hakkı ile, mevcut ortakların ortaklıkta biriktirilmiş zenginliklerini, bir çıkar karşılığı olmaksızın üçüncü kişilere transferini önlemek amacıyla, mevcut ortaklara yeni çıkarılacak hisse senetlerinden ortaklıktaki payı oranında satın alma olanağı sağlanmaktadır (Yükçü vd., 1999; 988).

Ortaklık açısından hisse senetleri, firmaya özkaynak niteliğinde finansman sağlayan bir araçtır. Hisse senetleri diğer menkul değerler gibi hakkı temsil eden belgelerdir. Bu belgelerin üçüncü şahıslara devri, üzerinde yazılı değer ve bağlı hakları da devir anlamına gelir. Yani hisse senedine bağlı olan haklar, senedin teslimi ile devredilir. Bu haklar, hisse senedi olmaksızın devredilemez.

### 3.3 Şirketler Neden Halka Açılır?

Şirketler, genellikle yaşam eğrilerinin bir parçası olarak, halka açılmaktadırlar. Şirketler önce girişimcilerin kendi olanakları ile kurulurlar. Kurulum aşamasından sonra ve henüz yeterli büyüklüğe erişmeden önce, şirketlerin kazançsız bir büyüme dönemi vardır ki, bu dönemde risk sermayesi adıyla anılan firmalar yeni özkaynak sağlama konusunda şirkete yardımcı olurlar. Eğer şirket başarılı olmaya devam ederse, işletme içinde yaratılan iç fonlar bir zaman sonra şirketin ihtiyaçlarına yetmemeye ve şirket, daha geniş bir sermaye kaynağına ihtiyaç duymaya başlayabilir. İşte şirketler, bu noktada hisse senetlerini halka açmaktadırlar. Bu ilk açılış ya da İHA (Initial Public Offerings-IPO) olarak tanımlanmaktadır.

Şirketlerin neden halka açıldıkları sorusunun cevabı, genellikle şirketin özkaynaklarını artırma ve şirketin kurucuları ile diğer paydaşlarının sahip oldukları zenginliği gelecekte nakde çevirebilecekleri bir piyasa yaratma isteği olarak verilmektedir. Ulusal değer kazanmak gibi finansal olmayan nedenler, pek çok şirket için ikincil önemde olabilmektedir (Ritter ve Welch, 2002; 1796).

Aslında şirketleri halka açılmaya yönlendiren, şirketin halka açılarak hem finansman ihtiyacını giderebilmesi hem de risk paylaşımından büyük faydalar sağlayabilmesidir (Pagano vd., 1998; 14). Örneğin halka açık olmayan bir şirket, kendi boyutlarını aşan büyük bir projenin finansman sorunu ve bu sorundan kaynaklanan bir risk ile karşı karşıya kalırsa, bu şirketin yapabileceği en iyi iş, tüm riski şirket sahibinin ya da yöneticisinin tek başına üstlenmesi yerine, hisse çıkararak bu riski birden fazla ortağa dağıtması olabilir. Yeni ihraçlar aracılığı ile şirkete ortak olacak yeni yatırımcılar da, kendi fonlarını muhtelif şirketler arasında dağıtarak kendi risklerini azaltabilirler.

Fon bulmak, şirketlerin hayatta kalabilmeleri ve finansal yapılarını sağlıklı bir şekilde sürdürebilmeleri için gerekli bir işlemdir. Bu aşamada önemli olan, bulunan fon kaynağının firmaya getireceği maliyet yükünün büyüklüğüdür. Öz kaynakla

finansman, belirli tarihlerde (temettü gibi) belirli ödemeleri yapma yükümlülüğünün bulunmaması nedeniyle bazı durumlarda borçla finansmana tercih edilebilmektedir. Halka açılma sayesinde şirketler, alternatif bir finansman kaynağına rahatlıkla erişebilmektedirler.

Tablo 7: Halka açılmanın yararları ve sakıncaları

Faktörler	Yararları	Sakıncaları
1. Dışarıdan Bir Yatırımcının İlk Kez Katılımı	- Şirket açısından sermaye artışı - Eski hissedarlar açısından karlılık, vergi avantajı sermaye kazancı, yatırım portföyü oluşturma, şirketi kontrol olanağı	- Harcanan zaman ve halka açılma masrafları - Yöneticilerin görev ve sorumluluklarında artış, geniş hissedarların çıkarlarını gözetme - Yönetimde sınırlamalar artar (bazı konularda genel kuru/un toplanması, kamuyu aydınlatma vb.)
2. Pazarlanabilirlik	- Hissedarların her zaman satma ve alma seçeneği - Hisse değerlerinin artması - Kote edilmiş hisselerin borçlanmada teminat olma niteliğinin artması - Şirket birleşmelerinde kote edilmiş hisselerin kabul görmesi	- Borsanın kotasyon şartlarına uyma zorunluluğu - Dahili bilgi kullanımı - Hisselerin dağılması ve şirket kontrolünün kaybolma olasılığı
3. Şirketin Şeffaflaşması	- Hisselerin borsada işlem görmesi, kapsamlı halkla ilişkileri gerektirir - Şirket itibarının artması, şirkete tavrıda değişiklik	- Dışarıya verilen bilgide artış - Hisse fiyatının şirketin barometresi gibi kabul edilmesi(karşılaştırma)
4. Felsefi Değişiklik	- Aile şirketinden profesyonel yönetime geçiş	- Halka açılmanın doğuracağı karmaşa ve artan genel giderler

Kaynak: Düzakın, 1998; 15

Halka açık olmayan şirketlerde hisse senetleri az sayıda kişinin elinde olması nedeniyle serbestçe pazarlanamamaktadır. Şirketler hisse senetlerinin pazarlanabilirliğini ve likiditesini artırabilmek için halka açılmak isteyebilirler.

Ayrıca halka açık bir şirketin imajı, halka açık olmayan şirketlere göre bazen daha olumlu olmaktadır. Halka açık şirketler, ulusal değerliliği kazanmış olarak görüldüğünden, kredi sağlama güçleri de yüksek olabilir. Bu da şirketlerin halka açılma nedenlerinden birisi olarak görülebilir.

Türkiye'de faaliyette bulunan şirketlerin karakteristik özelliği, aile şirketi kimliğine sahip olmalarıdır. Bu durum şirketin ömrünü, genelde kurucusu olan aile fertlerinin ya da yönetimde söz sahibi olan aile bireylerinin ömürleri ile sınırlayabilmektedir. Halka açılmak ve hisse senetlerinin menkul kıymet borsasında işlem görmesini sağlamak ile şirketler, sermaye piyasasının denetim mekanizmaları sayesinde kurumsallaşma süreçlerini hızlandırmakta ve modern yönetim tekniklerine daha kısa sürede kavuşabilmektedirler. Aile şirketlerinin profesyonel yönetime geçmek istemeleri de halka açılmanın nedenlerinden biri olarak açıklanabilir.

Türkiye'de özellikle 1990'lı yılların başından itibaren halka açılan şirket sayısında artış olduğu görülmektedir. Bu artışın nedenleri arasında halka açılmanın şirketlere sağladığı çeşitli üstünlüklerin önemli bir yeri vardır. Halka açılma, fon sağlamak için en hızlı ve en emin yollardan biridir. Fakat halka açılmanın da tamamen risksiz olduğu söylenemez. Zorunlu halka açılma aşamasında bazı sıkıntı verici durumlarla karşılaşmaktadır. Bunlardan en önemlisi ise halka açılan şirketin sahiplik yapısının değişmesiyle, kurucuların şirket üzerindeki kontrolünün zayıflaması ya da azalmasıdır (Brennan ve Franks, 1997; 16; Durukan, 2006; 7-8; ). Halka açılmanın sağladığı yararlar ve sakıncalar, Tablo 7'de olduğu gibi, dışarıdan bir yatırımcının ilk kez katılımı, pazarlanabilirlik, şirketin şeffaflaşması ve felsefi değişiklik gibi faktörler açısından değerlendirilebilir. Halka açılma kararı verilirken, elde edilecek yararlar ile birlikte yapılacak fedakârlıklar da göz önünde bulundurulmalıdır.

### 3.4 Halka Açılma Süreci

Şirketlerin hisse senetlerini halka arz etmesi ve menkul kıymet borsalarında işlem görmeye başlamaları, SPK ve İMKB'nin incelemelerini içeren bir süreçtir.

Şirketlerin hisse senetlerinin halka arzına ve borsada işlem görmesine karar vermesinden hisse senetlerinin borsada işlem görmeye başladığı ilk güne kadar uygulanan prosedür aşağıda belirtilmiştir ([www.imkb.gov.tr/yayinlar/halkaarz](http://www.imkb.gov.tr/yayinlar/halkaarz); Ritter, 1998; 3-4)

#### 1. Ön Hazırlık

Bir şirket hisse senetlerini halka arz etmeye karar verdikten sonra 6 aydan 2 seneye kadar değişen uzun bir hazırlık dönemi geçirmektedir. Hazırlık sürecinde, öncelikle halka arza aracılık yapmaya yetkili bir aracı kurum belirler.

Aracı kurum, bir şirketten bir menkul kıymet ihracı satın alıp bunu halka satan firmadır. Hisselerini ihraç eden şirket, arz edilecek hisse senetlerinin fiyatlanmasında ve pazarlanmasında yardımcı olması için, yetkili aracı kurum, muhasebeciler ve hukukçulardan oluşan bir ekip kurar. Yapılan toplantılarda, ekip bir işletme planı geliştirir, her ekip üyesine görevler atanır ve halka açılma programı bir zaman çizelgesine dökülür.

Bir hisse senedi halka satılmadan önce, şirketlerin hisselerini SPK'na tescil ettirmeleri gerekmektedir. SPK'nın incelemesine sunulmak üzere, bir tescil beyannamesi hazırlanır. Bu beyannamenin ilk kısmında hisse senedinin ihracına yönelik resmi özet bilgiler bulunur, bu kısım izahname olarak anılmaktadır. İzahname, son 5 yıla ait şirketin tüm finansal tabloları, yönetim kadrosu, şirketin hedef pazarının tanımı, rakipleri ve büyüme stratejisi gibi bilgileri içerir. Hazırlanan mali tabloların detay düzeyi ise şirketin büyüklüğüne, elde edilmek istenen sermaye miktarına ve şirketin yaşına bağlıdır.

## 2. Müracaat

Hisse senetlerinin SPK kaydına alınması ve halka arz edilmesinden sonra borsada ilgili pazarda işlem görebilmesi için, şirket izahname ve gerekli diğer belgeler ile SPK ve İMKB'ye eşzamanlı olarak müracaatta bulunur. Müracaatı şirket adına yetkili aracı kurum da gerçekleştirebilmektedir.

## 3. SPK'nın İMKB'den Görüş İstemesi

SPK, halka arz izahnamesine yazılmak üzere başvuru ile birlikte başvuruda bulunan şirketin hisse senetlerinin İMKB'nin hangi pazarında işlem görebileceğine dair görüşünü talep eder.

## 4. İncelemeler

SPK ve İMKB başvuruda eksik belgeler söz konusu ise söz konusu belgelerin tamamlanmasını talep eder. Belgelerin tamamlanması ile birlikte Şirket genel merkezi ve üretim tesisleri SPK ve İMKB uzmanları tarafından ziyaret edilerek incelemelerde bulunulur. SPK'nın görevi, İHA sürecinde olan bir şirketin kamuoyuna verdiği bilgilerin doğruluğunu kontrol etmektir, bu kurumlar İHA fiyatına müdahale etmezler.

## 5. Ön Talep Toplama

Hisselerinin SPK kaydına alınmasından önce, belirli bir fiyat aralığında yatırımcıların olası taleplerini öğrenmek amacı ile, talepte bulunanlar için herhangi bir yükümlülük ve bağlayıcılık oluşturulmaksızın aracı kuruluşlar tarafından bir ön izahname düzenlenerek ön talep toplanabilir. Duyuru ilanı yoluyla ön talep toplanabilir. Ön talep toplama, İHA'nın başarısını belirleyen en kritik faktörlerden biridir.

## 6. SPK'ya Görüş Gönderilmesi

İMKB uzmanlarının şirketle ilgili tüm inceleme raporları, İMKB Yönetim Kuruluna sunulur ve burada şirket hisse senetlerinin İMKB'de işlem görüp göremeyeceği karara bağlanır. Alınan karar SPK'ya iletilir.

## 7. Hisse Senetlerinin SPK Kaydına Alınması

SPK tarafından yapılan incelemeler neticesinde hazırlanan rapor ile İMKB'nın şirket hisse senetlerinin işlem görebileceği pazar hakkındaki görüşü çerçevesinde şirket hisse senetleri SPK tarafından kayda alınır.

## 8. Hisse Senetlerinin Halka Arz Edilmesi

Hisse senetlerinin SPK kaydına alınmasından sonra, onaylanmış izahname, kayıt belgesi tarihinden itibaren 15 gün içinde ortaklığın kayıtlı bulunduğu Ticaret Siciline tescil ve T. Ticaret Sicili Gazetesinde ilan ettirmek zorundadır.

Söz konusu tescil ve ilandan sonra, 15 gün içerisinde izahname ve tasarruf sahipleri için sirküler basın yayın yolu ile yatırımcılara duyurularak hisse senetlerinin alımı için yatırımcılara davette bulunulur. Sirkülerde belirtilen tarihlerde, izahnamede belirtilen satış yöntemine uygun olarak hisse senedi satış işlemine başlanır.

Genellikle şirketler yaklaşık olarak hisselerinin %15ini halka arz etmektedirler. Ayrıca halka arz edilen hisse senetlerinin % 15 ine kadar da bir ek satış hakkı söz konusu olup, arzu edildiği takdirde halka arzdan sonra bu ek satış hakkı da kullanılabilir.

Hisse senetlerinin halka arzı, biri *ortak satışı* diğeri *sermaye artırımı* olmak üzere iki şekilde gerçekleştirilebilmektedir. Ortak satışı, şirketin ortaklarının mevcut hisse senetlerinin ihraç edilmesidir. Sermaye artırımı ise, halka açık olan ve olmayan şirketler şeklinde iki ayrı durumda incelenmektedir. Halka açık olmayan ortaklıklar,

yapacakları sermaye artırımlarında, ortakların yeni pay alma haklarını kısmen veya tamamen kısıtlayarak hisse senetlerini halka arz edebilirler. Sermaye artırımında bu iki durum arasında yalnızca hisse senetlerinin halka arz prosedüründe farklılıklar bulunmaktadır.

Halka arzlarda *talep toplama* veya *borsada satış* şeklinde iki satış yöntemi bulunmaktadır. Türkiye’de hisse senedi satışı yapacak olan ortaklıklar, bu iki yöntemden birini seçebilmektedirler. (Sorularla Borsa, 2003; 8). Talep toplama yöntemi, sabit fiyatla talep toplama veya değişken fiyatla talep toplama şeklinde ikiye ayrılmaktadır. Değişken fiyatla talep toplama yönteminde asgari bir satış fiyatı tespit edilip, bunun üzerindeki fiyat teklifleri toplanırken, sabit fiyatla talep toplama yönteminde ise teklifler belirlenmiş tek bir fiyattan alınmaktadır. Borsada satış yöntemi ile satış, İMKB yönetmelikleri çerçevesinde yapıldığından asgari 20 işgünü önceden Borsa'ya başvurulması gerekmektedir.

### 3.5 Türkiye’de Halka Arza Aracılık Faaliyeti

Aracı kurumlar, bir menkul kıymet ihracını bir şirketten alıp halka satan yatırım bankacılığı firmalarıdır. Aracı kurumların, şirketlere işlemsel ve finansal konularda danışmanlık hizmeti vermek, şirketlerin halka ilk kez arz edilecek hisse senetlerini satın almak ve bunları halka satmak şeklinde üç temel rolleri vardır (Brealey vd, 1996; 375).

Aracı kurumlar, stratejilerin belirlenmesi ve halka ilk kez ihraçlarda çok önemli rol oynarlar. Özellikle çok büyük ihraçlarda prestiji yüksek, deneyimli ve finansal kaynakları güçlü olan aracı kurumlar tercih edilmektedirler. Şirketi halka açacak deneyimli ve güvenilir aracı kurumların bir araya getirilmesi de oldukça önemlidir. Eğer ihracın miktarı çok büyük ise birden fazla aracı kurum bir araya gelerek konsorsiyum oluşturulur. Bu durumda bir aracı kurum konsorsiyum liderliğini üstlenir. Lider aracı kurum, şirketin değerinin belirlenmesinde etkilidir (Griffin vd, 2004)



Sermaye piyasasında aracılık, sermaye piyasası araçlarının, Kanunun ilgili maddeleri çerçevesinde yetkili kuruluşlar tarafından kendi nam ve hesabına, başkası nam ve hesabına, kendi namına başkası hesabına ticari amaçla alım satımıdır. Aracılık faaliyeti SPK'dan yetki belgesi almış aracı kurumlar tarafından yürütülür.

Türkiye'de sermaye piyasasında aracılık faaliyetleri, halka arza ve alım satıma aracılıktan oluşmaktadır. Burada halka arza aracılık fonksiyonu ele alınacaktır. Halka arza aracılık *en iyi gayret aracılığı* ve *aracılık yüklenimi* olmak üzere iki şekilde yapılmaktadır. Aracılık yüklenimi de kendi arasında *tümünü yüklenim* ve *bakiyeyi yüklenim* şeklinde gerçekleşmektedir. (Düzakın, 1998; 45)

### 1. En İyi Gayret Aracılığı Yöntemi

Bu yöntemde aracı kurum, halka arzda bulunan şirketin bütün hisse senetlerini satmak için çaba sarf eder. Ancak bütün hisse senetlerinin satılamaması durumunda aracı kurum, hisse senetlerinin satılmayan kısmını kendisi satın almak mecburiyetinde değildir. En iyi gayret aracılığının en yaygın kullanılan şekilleri *hep ya da hiç* ve *minimum yüzdenin yüklenimi*dir. Bunlar:

- **Hep ya da Hiç Yüklenim Yöntemi:** Bu yöntemde aracı kurum bütün hisse senetlerini satmak için çaba sarf etmektedir. Fakat bütün hisse senetlerinin satılamaması halinde, hiçbirinin satılmadığı düşünülmekte ve arz iptal edilmektedir.
- **Minimum Yüzdenin Yüklenimi:** Bu yöntemde de aracı kurum bütün hisse senetlerini satmak için çaba sarf etmektedir. Eğer daha önceden belirlenen minimum tutardaki hisse örneğin %50 ya da %75 satılmış ise ihracın başarılı olduğu kabul edilir. Aracı kurumun satılamayan kısmı satın alma yükümlülüğü yoktur.

## 2. Aracılık Yüklenimi

Aracılık yüklenimi, halka arz edilecek sermaye piyasası araçlarının tamamının satılacağına aracı kurum tarafından ihraççı şirkete taahhüt edilmesidir.

*Bakiyeyi yüklenim ve tümünü yüklenim* olmak üzere iki türü vardır. Bunlar:

- **Bakiyeyi yüklenim**: Sermaye piyasası araçlarının, aracı kurumlarca halka arz yoluyla satılmasını ve satılmayan kısmının tamamının bedelinin satış süresi sonunda tam ve nakden ödenerek satın alınacağına satışı yapana karşı taahhüt edilmesini ifade eder.
- **Tümünü yüklenim**: Sermaye piyasası araçlarının bedeli nakden ödenmek suretiyle, tamamının satın alınarak satışın başlamasından sonra halka satılacağına satışı yapana karşı taahhüt edilmesidir.

Aracı kurumların aracılık faaliyetleri sırasında kısmen ya da tümüyle, sermaye piyasası araçlarının halka arza aracılığına ilişkin olarak ön hazırlıklar çerçevesinde mali ve ekonomik tahliller ile pazar araştırmaları yapmaları, izahname ve kayıt başvurusu için SPK'ya sunulacak diğer bilgi ve belgeleri hazırlamaları ve başvuruda bulunmaları da halka arza aracılık faaliyeti kapsamında sayılmaktadır.

Türkiye'de sermaye piyasası araçlarının halka arzına aracılık faaliyetini gerçekleştirecek aracı kurumlarda bazı şartlar aranmaktadır. Bu şartlar (SPK Seri;5 No: 19 Tebliği md 9):

- Aracı kurumlar için ödenmiş sermayelerinin asgari 10.000 YTL olması,
- Bünyelerinde, "halka arza aracılık işlemlerini" yürütebilecek, yüksek öğrenim görmüş ve mali tahlil konularında en az üç yıllık mesleki tecrübesi bulunan ve özellikle bu görev için istihdam edilmiş yeterli sayıda ihtisas personelinden oluşan bir kadro ile halka arza aracılık ve araştırma faaliyetlerini sürdürecektir düzeyde yeterli mekan, teknik donanım ve organizasyonu sağlamış olmalarıdır.

Bu şartlara sahip olmayan aracı kurumlar, SPK'nın ilgili tebliğine göre halka arzda aracılık faaliyetinde bulunamazlar.

### 3.6 Halka İlk Arzlarda Hisse Senetlerinin Düşük Fiyatlanması

İlk halka arz sürecinde üç taraf bulunmaktadır: Hisse senetlerini ihraç eden şirket, aracı kurum ve yatırımcılar. Bu süreçte, hisse senetlerini ihraç eden şirket, sermayesini, yatırımcılar ise getirilerini artırmak amacını taşır. Aracı kurumun görevi ise bu iki taraf arasındaki asimetrik bilgiyi azaltmaktır.

Düşük fiyatlama, hisse senetlerinin gerçek değerinin altında saptanmış bir fiyattan ihraç edilmesidir. Bir hisse senedinin düşük fiyatlanma oranı, *ilk gün getirisi* ya da *masa üstünde bırakılan para* miktarı ile ölçülebilmektedir. İlk gün getirisi, hisse senedinin ilk işlem günü sonundaki fiyatı ( $P_1$ ) ile halka arz fiyatı ( $P_0$ ) arasındaki farkın halka arz fiyatına oranlanması ile bulunur (Habib ve Ljungqvist, 1998; 382). Masa üstünde bırakılan para miktarı ise, hisse senedinin ilk işlem günü sonundaki fiyatı ile halka arz fiyatı arasındaki farkın ilk gün satılan hisse sayısı ile çarpımından elde edilir (Ritter ve Welch, 2002; 1796).

$$\text{dusuk fiyatlamannın getirisi} = \frac{P_1 - P_0}{P_0}$$

$$\text{Masa üstünde bırakılan para} = (P_1 - P_0) * \left( \begin{array}{l} \text{ilk gün satılan} \\ \text{hisse senedi sayısı} \end{array} \right)$$

Halka ilk kez arz edilen hisse senetlerinin performansları ile ilgili olarak yapılan çalışmalar (Tablo 6), bu hisse senetlerinin genelde düşük fiyatlandırıldığını ve piyasada işlem gördükleri ilk günde prim yaptıklarını göstermektedir. Bu durumda, özkaynağını artırma niyeti ile hisse senedi ihraç eden şirket, düşük fiyatlama yüzünden bazen kendilerine büyük miktarlarda özkaynak sağlayabilecek parayı yatırımcılara bırakmış olmaktadır.

Düşük fiyatlama, halka ilk arzlarda hisse senedi satın alarak zengin olunacağı anlamına gelmemektedir. Eğer bir ihraç düşük fiyatlandırılırsa, satın almak isteyen kişi sayısının çok olması nedeniyle aracı kurumun elinde herkese yetecek kadar hisse

senedi olmayabilir. Bu nedenle, bu tip sıcak ihraçlarda (halka ilk kez arz edilen hisse senedinden daha fazla talep olması durumunda) sadece küçük bir pay elde etme olasılığı vardır. Eğer hisse senetleri yüksek fiyatlandırılırsa, çoğu yatırımcı bu senetleri satın almayı istemeyebilir. Bu durumda hisse senedini satabilen aracı kurum memnun olacaktır. Bu *kazananın belası* (winner's curse) olarak tanımlanmaktadır. Kazananın belası, hangi ihraçların düşük fiyatlandırıldığına bilinmediği sürece, ucuz ihraçlardan küçük bir pay, pahalı ihraçlardan da büyük bir pay almanın mümkün olduğunu ifade etmektedir. Zarlar bilgi verilmemiş yatırımcıların aleyhine hileli olduğundan, onlar oyunu yalnızca, ortalamada önemli bir düşük fiyatlama varsa oynayacaklardır (Brealey, vd. 1997; 377).

Yukarıda bahsedilen, asimetric bilgiye dayanan *kazananın belası* hipotezinin yanı sıra, hisse senetlerinin halka ilk arzda düşük fiyatlandırılmasının nedenlerini açıklayan başka hipotezler de geliştirilmiştir. Bu hipotezler birbirinden bağımsız olmamalarının yanı sıra, asimetric bilgi, kurumsal nedenler, sahiplik ve kontrol ve davranışsal açıklamalar şeklinde dört ana grupta incelenebilir (Ljungqvist, 2005; 2).

### 3.6.1 Asimetric Bilgi Modelleri

Düşük fiyatlama ile ilgili hipotezlerin en yerleşik olanı, asimetric bilgiye dayalı modellerdir. Daha önce de bahsedildiği gibi, bir İHA sürecinin ilgili taraflarını hisse senedini ihraç eden şirket, yetkili aracı kurum veya yatırımcılar oluşturmaktadır. *Asimetric bilgi modelleri*, taraflardan birinin diğerlerine göre daha fazla bilgiye sahip olduğunu belirtmektedir. Baron (1982) yılında yaptığı çalışmada düşük fiyatlama olgusunu hisse senedini ihraç eden şirket ile aracı kurum arasındaki asimetric bilginin varlığına bağlamıştır. Baron, aracı kurumların sermaye piyasası konusunda hisse senedi ihraç eden şirketlerden daha fazla bilgiye sahip olduklarını ileri sürmektedir. Hisse senedi ihraç eden şirket, piyasadaki belirsizlikler nedeniyle fiyat kararını aracı kuruma bırakır ve hisse senetlerinin daha düşük fiyatlandırılacağını kabul eder. Böylece fiyatlama kararını veren aracı kurum, sahip olduğu bilgiye karşılık olarak düşük fiyatlama sayesinde riskten kaçınma imkânı

bulmaktadır. Bu hipotez fiyatlama sürecinde aracı kurumların daha etkili olacağını varsaymaktadır.

Muscarella ve Vetsuypens (1989) yaptıkları çalışmada Baron'un hipotezini desteklememişlerdir. Muscarella ve Vetsuypens hisse senetlerinin halka ilk arzını kendileri gerçekleştiren aracı kurumların halka ilk arzlarındaki değerleri dikkate alarak modeli test etmişlerdir. İhraç eden aracı kurum olduğunda, Baron'un hipotezindeki gibi bir asimetrik bilginin söz konusu olmadığını, aracı kurumların kendi hisse senetlerini halka ilk kez arz ettiğinde de düşük fiyatlandıklarını göstermişlerdir. Genel olarak, hisse senetlerinin düşük fiyatlandırılması ihraç eden firma ve aracı kurum arasındaki asimetrik bilgi ile ilgili ise, hisse senetlerini halka ilk kez arz eden aracı kurum onları düşük fiyatlandırmayacaktır.

Asimetrik bilgi hipotezini açıklayan diğer bir model ise Rock (1986) tarafından geliştirilmiştir. Ancak Rock'a göre asimetrik bilgi hisse senedi ihraç eden şirket ile aracı kurum arasında değildir. Pazarda iki grup potansiyel yatırımcı bulunmaktadır. Birinci grupta yer alan potansiyel yatırımcılar, halka ilk kez arz edilecek hisse senedinin gerçek değerini bulmada gerekli bilgiye sahiptir. Bu yatırımcılara bilgili yatırımcılar denilmektedir. Bu yatırımcıların piyasa oluşturmalarına karşılık ödül olarak düşük fiyatlandırma yapılmaktadır. İkinci grupta ise halka ilk kez arz edilen her yeni hisse senedini aralarında fark gözetmeksizin rast gele alan bilgilendirilmemiş yatırımcılar yer almaktadır. Halka ilk kez arz edilen hisse senetlerinin fiyatı konusunda her zaman bazı belirsizlikler vardır. Bu nedenle hisse senedi ihraç eden şirketler ve aracı kurumlar, hisse senetlerini tüm yatırımcıları tatmin edecek bir fiyattan arz etmeye yönelirlerse, bilgilendirilmemiş yatırımcılar yüksek fiyatlandırılmış hisse senetlerinden büyük miktarlarda alım yapmaktan vazgeçebilirler. Rock'a göre bilgilendirilmemiş yatırımcıları pazarda tutabilmek için aracı kurumlar belirli bir miktar daha düşük fiyatlandırma yoluyla bilgilendirilmemiş yatırımcılara bırakmaktadırlar. Böylece bilgilendirilmemiş yatırımcılar, yüksek fiyatlandırılmış hisselerden doğan zararlarını kapatma imkânına kavuşacaklardır.

### 3.6.2 Kurumsal Nedenler

İlk halka arzların düşük fiyatlanmasına ilişkin kurumsal nedenler şunlardır:

Bunlardan birincisi, *sigorta hipotezidir*. ABD'de 1933 yılından beri geçerli olan Kıymetli Evrak Yasasına (Securities Act of 1933) göre aracı kurumlar ve hisse senetlerini halka arz eden şirketler kamuoyuna her türlü bilgiyi yansıtmakla yükümlü olup, aracı kurumun şirket ile ilgili her türlü araştırmayı yapması gerekmektedir. Sigorta hipotezinin temel savunusu, Tınıç'ın 1988'de yaptığı çalışmasında gösterdiği gibi, aracı kurumun ve ihraççı şirketin, İHA sonrası hisselerin performansından hayal kırıklığına uğrayabilecek ortakların dava açma riskini azaltmak için İHA'da hisse senetlerinin düşük fiyatlandırıldığı yönündedir. Fakat daha sonra Drake ve Vetsuypens, 1933 yılındaki Federal Kıymetli Evrak Yasası'nın kabulünden sonraki dönemde, 1969–1990 yılları arasında halka açılan ve halka ilk arzda hazırladıkları izahnamedeki yanlış bilgilendirmeden dolayı haklarında dava açılan 93 firmayı içeren bir çalışma yapmışlardır. Drake ve Vetsuypens çalışmalarında bu firmaların halka ilk arzındaki ilk günlük getirilerin ortalamasını %9.18 olarak bulmuşlardır. Bu sonucun da diğer halka ilk arzlardaki düşük fiyatlandırmaya benzer olduğunu ve dava edilmeyi önlemek için düşük fiyatlama yapıldığının ileri sürülemeyeceğini belirtmişlerdir (Drake ve Vetsuypens, 1993)

Bir diğer kurumsal yaklaşım, *fiyat müdahalesi* uygulamasına dayanır. Aracı kurumların İHA'ya yönelik sağladığı hizmetlerden biri de *fiyat stabilizasyonudur*. Fiyat stabilizasyonunda amaç, hisselerin piyasaya çıktıktan birkaç gün ya da hafta sonraki fiyat düşüşlerini azaltmaktır. Düşük fiyatlamanın getirileri, pozitif bir ortalama etrafında simetrik olmaktan ziyade, sıfırda keskin bir şekilde yükselen ve nadiren sıfırın altına düşen sağa çarpık bir dağılışa sahiptirler. Ruud (1993) İHAların kasıtlı olarak düşük fiyatlanmadığını göstermek için, bu istatistiksel dağılışları başlangıç noktası olarak almıştır. İHAlar beklenen piyasa değerine göre fiyatlandırılırlar, fakat piyasada işlem görmeye başladıktan sonra fiyatları, arz fiyatının altına düşme tehlikesi olan arzlara müdahale edilir. Bu fiyat müdahalesi, ilk gün getirilerin dağılışının sol tarafını ortadan kaldırmak ve ortalama olarak pozitif bir

fiyat sıçraması görüntüsünü vermek için yapılmaktadır. Bu nedenle, verilerde gözlediğimiz şey, gerçek ilk gün getirilerinin ortalaması değil, piyasa sonrası aracı kurumun müdahalesinden kaynaklanan bir ortalama olabilir (Ljungqvist, 2005; 45)

Üçüncüsü ise, İHA'ları düşük fiyatlamanın vergi avantajlarının olmasıdır. Sermaye kazançlarından doğan gelir vergisine yönelik vergi oranları, çalışma sermayesinden elde edilen gelirlerin vergi oranlarından daha düşüktür. Bu oranlar arasındaki farkın avantajından fayda sağlamak isteyen yöneticiler, İHA'ları düşük fiyatlandırmaya eğilimli olabilirler. Vergi avantajı ve düşük fiyatlamanın maliyeti arasındaki karşılaştırma sonucunda, yöneticiler vergi durumuna bağlı olarak daha fazla ya da daha az düşük fiyatlamayı tercih edebilirler (Ljungqvist, 2005; 49-50).

### 3.6.3 Sahiplik ve Kontrol

Sahiplik yapısının şirketin değerini ve halka açılma kararını etkilediği çeşitli araştırmacılar tarafından bulunmuştur. Örneğin, Brennan ve Franks (1997) bir şirketin sahiplik yapısının hisse senetlerinin düşük fiyatlanmasında önemli bir role sahip olabileceğini ileri sürmüşlerdir. Halka açılma genellikle, sahiplik ve kontrol yapısının birbirinden ayrılmasına doğru atılan bir adım olarak görülmektedir. Özellikle, sahiplik ve kontrol yapısının birbirinden tamamen ayrıldığı durumlarda, yönetimde olan ve olmayan ortaklar arasında bir temsiliyet problemi ortaya çıkabilmektedir (Ljungqvist, 2005; 51). Bu nedenle İHA öncesi şirketin sahipleri, büyük paylara dolayısıyla yönetime katılma hakkına sahip ortaklıklardan ziyade, yeni yatırımcıların şirketi ve yöneticileri izlemeleri beklentisine dayanarak İHA'ları düşük fiyatlamayı seçmektedirler. Buradan birbiriyle çelişen iki görüş ortaya çıkmaktadır. Biri düşük fiyatlamanın, yeni ortaklar tarafından izlenmekten kaçınmak için sahiplik yapısını yayma amacıyla kullanıldığını ileri sürerken, diğer görüş, yatırımcıların yöneticileri dışarıdan bir gözle izlemelerinden faydalanmak amacıyla düşük fiyatlamanın kurumsal yatırımcıları çekmede kullanıldığını belirtmektedir (Durukan, 2006; 21).

### 3.6.4 Davranışsal Açıklamalar

Birçok arařtırmacı düşük fiyatlamamanın yüksek seviyelerde olmasını, asimetrik bilgiler, dava riskleri veya kontrol gücü ile ilgili sebeplere dayandırmaktadır. Bazı arařtırmacılar ise, düşük fiyatlamamanın nedenlerinin davranışsal açıklamalarda bulunabileceğini belirtmektedir. Davranışsal teoriler, hem İHA hisselerinin gerçek deęerinin üzerine çıkmasına yol açan irrasyonel yatırımcıların varlığını, hem de ihraççıların davranışsal yanılırlara kapılıp aracı kurumlara düşük fiyatlama yapması konusunda baskı yaptığını ileri sürmektedirler(Ljungqvist, 2005; 57). Fakat bu konuda yazın henüz olgunlaşmamıştır.



## 4 YAPAY SİNİR AĞI MODELİNİN TASARIMI

### 4.1 Yöntem

Bu çalışmanın temel amacı, en az istatistiksel modeller kadar öngörü doğruluğuna sahip bir yapay sinir ağı modelinin geliştirilmesidir. Yapay sinir ağları özellikle finans alanında çok yaygın kullanılan bir tekniktir. Yazında finansal alanda pek çok YSA uygulamasına rastlanmakta ve özellikle finansal tahminleme konusunda, öğretmenli öğrenme stratejisini kullanan çok katmanlı algılayıcı YSA modelinin başarılı bir şekilde uygulandığı görülmektedir. Kaastra (1994), finansal tahminleme için geriye yayma algoritmasının kullanıldığı YSA mimarilerinin en uygun yapılar olduğunu belirtmiştir. Bu bölümde, yazındaki başarılı uygulamaları dikkate alarak, ilk halka arzların fiyat performanslarının tahmininde geriye yayma algoritmasının kullanıldığı bir YSA modeli geliştirilmiştir.

YSA modeli tasarlanırken, ilk olarak tahmin edilecek olan bilginin ne olacağı belirlenmiştir. Halka arzların ilk gün fiyat performansları, arz edilen hisse senedinin ilk işlem gördüğü günün sonundaki kapanış fiyatı ( $P_1$ ) ile tahmin edilmiştir. Tahmin edilecek bilgi olarak  $P_1$ 'in seçilmesinin nedeni, halka hisse senedi ihraç eden şirketlerin hisse senetlerinin piyasa değeri konusunda bilgi sahibi olmasını sağlamaktır. Daha önce de belirtildiği gibi, ilk halka arzlarda hisse senetleri çoğunlukla düşük fiyatlandırılmaktadır. Düşük fiyatlamamanın nedenlerini açıklayan hipotezler, bu konuyu ihraç eden şirket, aracı kurum ve yatırımcı olmak üzere üç taraf açısından değerlendirmektedir. Her bir hipotezin haklı yönleri ile bakılırsa, ilk halka arz edilen hisse senedinin, ilgili tüm tarafların çıkarlarını dengeleyecek bir şekilde fiyatlanması önemlidir. Örneğin, aşırı derecede düşük fiyatlama yapıldığında, yatırımcılar bu duruma sevinirken, ihraç eden şirket elde edebileceği büyük miktardaki sermayeyi yatırımcılara bırakmış olmaktadır. Hisse senedini ihraç eden şirketin bu tür fırsat kayıplarına maruz kalmaması ve diğer tarafların çıkarlarının da dengelenebilmesi açısından, hisse senedini ihraç eden şirket ile aracı kurumun, hisse

senedinin piyasa deęerini bilerek ilk halka arz fiyatını ( $P_0$ ) belirlemeleri yerinde bir yaklaşım olacaktır.

#### 4.1.1 Örneklerin Toplanması

YSA modeli geçmişteki örneklerden öğrenmektedir. Ağın performansını yakından ilgilendiren bir konu olduğu için, seçilen örneklerin problem uzayını temsil edebilecek nitelikte olması önemlidir. Seçilen örnekler daha sonra eğitim seti ve test seti olmak üzere ikiye ayrılmaktadır.

Bu çalışmanın kapsamını, Türkiye’de 1995 ile 2004 yılları arasında gerçekleşen halka arzlar oluşturmaktadır. Halka açılan şirketlere ait geçmiş veriler, İMKB ve SPK’nın resmi internet sitelerinden; borsada işlem gören hisse senetleri ve bunları ihraç eden şirketlere ilişkin finansal bilgilere erişime izin veren özel sitelerinden elde edilmiştir. Elde edilen veriler, girdiler şeklinde ağa beslenmiştir.

Her ne kadar tanımlanması zor olan ilişkileri bulmada yapay sinir ağlarının iyi performans gösterdiği bilinse de, bunun için girdi ve çıktı arasında ilişkiler olması gerekir. İHA’nın ilk gün kapanış fiyatını tahmin etmede kullanılan değişkenler şunlardır:


1. Arz oranı: Halka arz edilen hisse senetlerinin sermayeye oranıdır. (ARZORANI)
2. Halka arz hasılatı. İlk halka arz hasılatı, ihraç edilen hisse senedi sayısı ile ilk halka arz fiyatının çarpımından elde edilmektedir. Enflasyon etkisini ortadan kaldırmak için, burada halka arz hasılatı USD cinsinden hesaplanmıştır. Modele ise, bunun doğal logaritması hesaplanarak alınmıştır. (LNHASILA)
3. Sahiplik yapısı: Pagano v.d (1998), ilk halka arz sonrası sahiplik yapısının alacağı durumun, ilk halka açılma kararını ve ilk gün fiyat performansını etkilediğini ileri sürmüşlerdir. Modelde sahiplik yapısını ifade eden iki kukla değişkene yer verilmiştir: kurumsal sahiplik (KSAHIP) ve bireysel sahipliktir (BSAHIP). Bunlardan birincisi, hisse senedi arz edildikten sonra, herhangi bir

kuruluşun ihraçların %10'undan fazlasını alarak şirketin sahipliğine ortak olmasını ifade etmektedir. İkincisi ise, ihraçların %10'undan fazlasını bir bireyin alması durumudur. Her iki kukla değişken, modelde şirketin sahiplik yapısının değiştiği yönü göstermektedir.

4. Halka arz şekli: İHA'larda düşük fiyatlamamanın seviyesi kimin hisselerinin satıldığına bağlıdır (Durukan, 2002). Yatırımcıların, halka arz şeklinin sermaye artırımını (SERARTIR) veya ortak satışı (ORTSAT) şeklinde olup olmamasına bağlı olarak yatırım stratejileri farklılık gösterebilir. Bu iki yöntem ayrı ayrı kukla değişkenler olarak modele alınmıştır. İlk halka arz yönteminin ortak satışı şeklinde olması halinde, kukla değişken 1 değerini, aksi halde 0 değerini almaktadır. İlk halka arz yönteminin sermaye artırımını şeklinde olması halinde, kukla değişken 1 değerini, aksi halde 0 değerini almaktadır. Böylece her iki yöntemin kullanıldığı halka arzlarda bu değişkenin etkisi her iki değişkenin aynı anda 1 değerini almaları ile yansıtılmıştır).
5. Blok yatırımcı: Arz edilen hisselerin %5'inden fazlasını alan blok yatırımcının varlığı (BLOKYTRM)
6. Firmanın büyüklüğü: Şirketin halka açılmadan önce sahip olduğu toplam varlıkların doğal logaritması olarak hesaplanmıştır. (LNVARLIK)
7. Finansal kaldıraç oranı: Bu oran, yabancı kaynakların, toplam kaynaklar içindeki payını göstermektedir. İşletmenin kısa vadeli ve uzun vadeli yabancı kaynaklarının (toplam borç), toplam varlıklara oranlanması ile bulunur.(BORCVARL)
8. Yaş: Şirketin hisse senetlerini halka arz ettiği tarihteki yaşı, halka açıldığı tarihten kurulduğu yılın çıkarılmasıyla elde edilmiştir. Yaş değişkeni, (yaş+1)'in doğal logaritması şeklinde kullanılmıştır. (LN(YAS+1)).
9. Sektör: Şirketin bulunduğu sektör de, belirli katsayılarla hisse senetlerinin fiyatlarını etkilemektedir. (SEKTOR)
10. İndeks: İMKB100'ün indeks değeridir (İNDEKS)
11. Aracı kurum: Aracı kurum ile hisse senedini ihraç eden şirket arasında organik ilişkilerin olması ile olmaması arasındaki farklılıkları tespit etmek için modele alınmıştır. Modelde kukla değişken olarak yer almaktadır, eğer

aracı kurum ile şirket arasında ilişki varsa, değişken 1 değerini almaktadır  
(ARACIKRM)

12. Kriz: Bu değişken modele, kukla değişken olarak girmiştir. Eğer hisse senedinin arz edildiği yılda kriz olmuşsa, kriz değişkeni 1 değerini almıştır.  
(KRIZ)



Şekil 18: 1995-2004 yılları arasında gerçekleşen İHA sayısı

Yukarıda açıklanan değişkenlerle ilgili bilgilere erişim durumuna bağlı olarak, çalışmanın veri setinde 01 Ocak 1995 ile 31 Aralık 2004 tarihleri arasında gerçekleşen 165 İHA bulunmaktadır (Şekil 18). Yıllar itibariyle halka arzların sayısının düzgün olmadığı görülmektedir. 2001 yılında yaşanan kriz etkisiyle, bu yıldan itibaren halka arzların sayısında iyice azalma görülmektedir.

#### 4.1.2 Veri Analizi

Toplanan veriler ağa gösterilmeden önce bazı ön işlemlere tabi tutulmaları gerekmektedir:

## 1. Veri yapısının analizi

Veri yapısının analizi ile, verinin tipi, normallik durumu, kayıp değerler ve sapan değerler incelenmektedir. Araştırmanın bu bölümünde SPSS 11.0 istatistiksel paket programı kullanılmıştır.

Tablo 8: Tanımlayıcı istatistikler

Veri Tipi	Değişken	N	Minimum	Maksimum	Ortalama	Std. Sapma
Niceliksel	P0	165	1000	100000	11611,76	14233,01
Niceliksel	P1	165	890	105000	12480,58	15089,37
Niceliksel	LNP1	165	6,79	11,56	8,8997	1,0473
Niceliksel	İNDEKS	165	-0,091082	0,151453	-1,52E-03	3,46E-02
Niceliksel	ARZORANI	165	0,99	99,07	26,7896	19,0409
Niceliksel	LNHASILA	165	11,92	21,3	15,8319	1,3963
Niceliksel	LNYAS	165	0,69	4,2	2,3302	1,0134
Niceliksel	LNVARLIK	165	9	22,41	16,8104	2,6098
Niceliksel	BORCVARL	165	0	0,95	0,4202	0,284

Veri Tipi	Değişken	N	Minimum	Maksimum	Değer	Frekans	Yüzdellik
Niteliksel	ORTSATIS	165	0	1	0	91	55
					1	74	45
Niteliksel	SERARTIR	165	0	1	0	42	26
					1	123	76
Niteliksel	SEKTOR	165	1	10	1	8	5
					2	15	9
					3	15	9
					4	26	16
					5	5	3
					6	9	6
					7	15	9
					8	56	34
					9	7	4
					10	9	6
Niteliksel	KSAHIP	165	0	1	0	38	23
					1	127	77
Niteliksel	BSAHIP	165	0	1	0	119	72
					1	46	28
Niteliksel	BLOKYTRM	165	0	1	0	89	54
					1	76	46
Niteliksel	ARACIKRM	165	0	1	0	125	76
					1	40	24
Niteliksel	KRIZ	165	0	1	0	119	72
					1	46	28

Verilerde öncelikle kayıp değerlerin olup olmadığı kontrol edilmiştir. 165 hisse senedine ilişkin çeşitli değişken değerlerinde bazı kayıp değerlere rastlanmıştır. Veri setindeki bu kayıp değerler, hisse senedini arz eden şirketin bulunduğu sektördeki ortalama değerleri ile doldurulmuştur.

Tablo 8 de görüldüğü gibi girdi değişkenleri hem niceliksel hem de niteliksel veri tipine sahiptirler. Tablo 8a, niceliksel verilere Tablo 8b ise, niteliksel verilere ilişkin tanımlayıcı istatistikleri göstermektedir. Verilerin normallik durumları Kolmogorov-Smirnov testi ile incelenmiştir. Tablo 9’ de verilen normallik testi sonuçlarına göre, tüm test istatistiklerinin önem düzeyi sıfıra yakın değerler olduğundan, girdi değişkenlerinin hiçbiri normal dağılım göstermemektedir.

Tablo 9: Normallik testi

Normallik testi					
Veri Tipi	Değişken	N	Test istatistiği (*)	Önem düzeyi	Normal mi?
Niceliksel	P0	165	0,225	p<0,01	HAYIR
Niceliksel	P1	165	0,221	p<0,01	HAYIR
Niceliksel	LNP1	165	0,052	p>0,15	EVET
Niceliksel	İNDEKS	165	0,074	p=0,037	HAYIR
Niceliksel	ARZORANI	165	0,199	p<0,01	HAYIR
Niceliksel	LNHASILA	165	0,063	p=0,113	EVET
Niteliksel	ORTSAT	165	0,094	p<0,01	HAYIR
Niteliksel	SERART	165	0,096	p<0,01	HAYIR
Niceliksel	LNYAS	165	0,087	p<0,01	HAYIR
Niteliksel	SEKTOR	165	0,149	p<0,01	HAYIR
Niceliksel	LNVARLIK	165	0,182	p<0,01	HAYIR
Niceliksel	BORCVARLIK	165	0,077	p=0,025	HAYIR
Niteliksel	KSAHIP	165	0,095	p<0,01	HAYIR
Niteliksel	BSAHIP	165	0,096	p<0,01	HAYIR
Niteliksel	BLOKYTRM	165	0,094	p<0,01	HAYIR
Niteliksel	ARACIKRM	165	0,095	p<0,01	HAYIR
Niteliksel	KRIZ	165	0,096	p<0,01	HAYIR

(\*) Kolmogorov-Smirnov (Lilliefors Significance Correction)

İstatistiksel sapan değerler girdi-çıkıtı değişkenlerindeki aşırı değerlerdir. Hisse senedi piyasasına özgü davranışlar verilere yansıdığı için, sapan değerler veri setinden çıkarılmamıştır.

## 2. Korelasyon analizi

Yapay sinir ağının etkin bir şekilde çalışabilmesi için girdiler ve çıktı arasında bir ilişki olması gerekmektedir. Korelasyon analizi, girdi-çıkıtı arasında ilişki olup olmadığını ortaya çıkarmakta, fakat değişkenler arasında bir nedensellik ilişkisini göstermemektedir.

Tablo 10: Girdi değişkenleri ile çıktı değişkeni ( $\ln P_1$ ) arasındaki korelasyon

	KORELASYON*	ÖNEM DÜZEYİ
LNPI	1,000	1,000
İNDEKS	0,013	0,873
ARZORANI	-0,468	0,000
LNHASILA	0,348	0,000
ORTSAT	-0,028	0,726
SERART	0,077	0,325
LNYS	0,465	0,000
SEKTOR	-0,341	0,000
LNVARLIK	0,138	0,077
BORCVARL	0,310	0,000
KSAHIP	-0,024	0,761
BSAHIP	0,205	0,008
BLOKYTRM	0,179	0,021
ARACIKRM	-0,315	0,000
KRIZ	0,155	0,047

\*Spearman korelasyon katsayısı hesaplanmıştır.

Girdi ve çıktı değişkenleri arasındaki ilişkileri hesaplamada 2 yöntem kullanılmaktadır. Bunlar, Pearson ve Spearman rank korelasyon katsayılarıdır. Korelasyon matrisinden bahsedildiğinde, genelde Pearson-tipi korelasyon matrisi ifade edilmektedir. Fakat Pearson korelasyon katsayıları, sapan değerlerden, sabit olmayan varyanslardan, normal olmama ve doğrusal olmama durumundan çok fazla etkilenmektedir. Spearman korelasyon katsayısı ise, gerçek değerler yerine verilerin sıra değerlerine Pearson korelasyon formüllerini uygulayarak korelasyonu hesaplamaktadır. Sıra değerlerine bağlı olarak korelasyon katsayısını hesaplaması nedeniyle Spearman, Pearson korelasyon katsayılarının etkilendiği olumsuz faktörlerden etkilenmemektedir.

Burada kullanılan veriler normal olmadıkları için birçok sapan değer içermektedir. Bu nedenle, YSA modelindeki girdiler ve çıktı arasında ilişki olup olmadığını tespit etmek için, Spearman korelasyon katsayıları hesaplanmıştır.

### 3. Veri normalizasyonu

Yapay sinir ağına girdileri göstermeden önce, bunların normalize edilmesi ağın performansını yakından etkilemektedir. Verilerin normalizasyonu ile girdi verileri YSA'nın kabul edebileceği bir değer aralığına dönüştürülmektedir. Genelde kullanılan değişim aralığı  $[-1,1]$  veya  $[0,1]$  arasındadır.

Bu çalışmada kullanılan normalizasyon fonksiyonu, veri değer aralığı ne kadar geniş olursa olsun, girdi verilerini birbirlerine yaklaştırarak 0 ile 1 arasında değerlere dönüştüren logaritmik bir fonksiyondur.

$$\log \left[ \left( \frac{x - x_{\min}}{x_{\max} - x_{\min}} \right) (e - 1) + 1 \right]$$

Girdi verilerine yukarıdaki normalizasyon fonksiyonu uygulanmıştır. Bu şekilde, veri setindeki sapan değerlerin olumsuz etkileri bir derece azaltılmıştır. Bu fonksiyonun dışında, lojistik ve hiperbolik tanjant fonksiyonları da normalizasyon amacıyla kullanılabilir.

#### 4.1.3 Yapay Sinir Ağı Modelinin Geliştirilmesi

Yapay sinir ağı modelinin geliştirilmesinde MS Excel modülleri ile çalışan NeuroComputing adlı yazılımdan faydalanılmıştır. Bu yazılım, çalışmadaki yapay sinir ağı modellerini geliştirmede çok katmanlı algılayıcı modelini, öğrenme kuralını ve geçiş fonksiyonunu destekleyen bir yazılımdır. Yazılımın çeşitli parametre değişiklikleri konusunda bazı sınırlı özellikleri de bulunmaktadır. Yazılımda model



için tek ara katman oluşturulabilmekte ve maksimum 10000 iterasyon gerçekleştirilebilmektedir. Bu yazılım, eğitim sırasında geliştirilen ağın test verileri üzerindeki performans değerlerini ve ağın hatasının eş zamanlı olarak hesaplayabilmesi, gerçek verilerle modelin ürettiği verilerin karşılaştırılmasını ve modelin hata değişim aralığını ekranda grafiksel olarak gösterebilmesi özellikleri nedeniyle tercih edilmiştir. Yazılımın iterasyonların her adımında modelin ürettiği değerleri grafiksel olarak göstermesi nedeniyle, aynı zamanda ağın verileri ezberleyip ezberlemediği izlenebilmiştir.

Herhangi bir yapay sinir ağı modeli oluştururken öncelikle ağın mimarisini, kullanacağı öğrenme kuralını ve hatanın nasıl hesaplanacağını belirlemek gerekir. Finansal alanda en çok kullanılan mimari ve öğrenme algoritması olma özelliği göz önünde bulundurularak, ilk halka arzların fiyat performansını tahmin edecek olan yapay sinir ağı modelinin geliştirilmesinde çok katmanlı algılayıcı modeli ve öğretmenli öğrenme stratejisi uygulanmıştır. Çok katmanlı algılayıcının ileri beslemeli yapısından dolayı da öğrenme algoritması olarak hatayı geriye yayma kuralı kullanılmıştır. Modelin geliştirilmesi sırasında ağın bu özellikleri her denemede sabit tutulmuştur.

Aşağıda yapay sinir ağı modelinin geliştirilmesi sırasında uygulanan aşamalar özetlenmiştir.

### 1. Verilerin eğitime hazırlanması

NeuroComputing programında öncelikle verilerin belirli bir sırada çalışma sayfalarına yüklenmesi gerekmektedir. İlk sütunlara girdi değişkenlerine ait veriler, son sütuna hissenin ilk gün gerçek fiyatına ilişkin veriler yerleştirilmiştir. Son sütundaki veriler, eğitim sonrasında tahmin değerle kıyaslamada kullanılmaktadır.

Veriler sisteme girildikten sonra, ağına gösterilecek veri seti eğitim ve test seti olmak üzere ikiye ayrılmıştır. Verilerin seçimi ise rassal olarak yapılmıştır. Bunun için, her hisseye bir sıra numarası verilmiş ve bu sıra numaralarına MS Excel'in

rand() fonksiyonu kullanılarak birer rassal sayı atanmıştır. Veri seti rassal atanan değerlere göre küçükten büyüğe doğru sıralanmış ve bunların %80'i eğitim, %20'si ise test seti olarak ayrılmıştır. Bu oranlar yapılan her denemede aynı şekilde kullanılmıştır.

## 2. Ağın topolojik yapısının belirlenmesi

Ağın topolojisini belirleyen kullanılan girdi, ara katman ve çıktı katmanlarının sayısı ve her ara katmanda bulunan yapay nöron sayısıdır. Ağın tasarımı için, girdi katmanı-ara katman-çıkı katmanı şeklinde 3 katmanlı bir yapı oluşturulmuştur. Yapay sinir ağlarında en iyi topolojik yapıya ulaşmak için geliştirilmiş kurallar bulunmadığından, bu aşamada deneme-yanılma yöntemi kullanılmaktadır. Modeldeki üç katmanlı yapıda ara katmandaki nöron sayısına karar vermek çok sayıda denemeler yapılmıştır. Tek nörondan başlayıp her denemede nöron sayısı bir artırılarak ağın performansı değerlendirilmiş ve buna göre ara katman için gereken nöron sayısı belirlenmiştir.

## 3. Ağın parametrelerinin belirlenmesi

En iyi yapay sinir ağının geliştirilmesinde rol oynayan çeşitli parametreler bulunmaktadır. Bunlar, öğrenme katsayısı, momentum katsayısı, bağlantıların ağırlık değerleri, toplama ve geçiş fonksiyonlarıdır. Ağın topolojik yapısında olduğu gibi, en iyi yapay sinir ağı modeline ulaşmayı sağlayacak parametrelere ilişkin geliştirilmiş bir yöntem bulunmadığından, en uygun parametrelerin belirlenmesi deneme-yanılma yoluyla gerçekleştirilmiştir.

Ağın eğitilmesi sırasında, bir hücreye gelen net girdiyi hesaplamak için bir toplama fonksiyonunun, hücreye gelen net girdiyi işleyerek hücrenin bu girdiye karşılık üreteceği çıktıyı belirlemek için de bir geçiş fonksiyonunun belirlenmesi gerekmektedir. Herhangi bir ağ için, bu fonksiyonları belirlemenin bir formülü bulunmamaktadır. Lubis (2000), çalışmasında finansal verilerde tanjant hiperbolik fonksiyonunun en iyi sonuçları ürettiğini göstermiştir. Bu çalışmanın sonucu, burada

geliştirilen modelin geçiş fonksiyonunu belirlerken girdi olarak alınmıştır. Buna göre, yapılan tüm denemeler de toplama fonksiyonu olarak doğrusal fonksiyon, geçiş fonksiyonu olarak da hiperbolik tanjant fonksiyonu kullanılmıştır.

Öğrenme katsayısı bağlantı ağırlıklarının değişim miktarını belirlemektedir. Büyük değerler seçildiğinde ağ oldukça hızlı öğrenmektedir, fakat bu durumda ağırlıklar arasında osilasyonların gerçekleşmesi ve ağın yerel çözümler arasında dolaşması söz konusu olabilmektedir. Küçük değerler seçildiğinde ise ağın öğrenme zamanı artmaktadır. Önceden yapılan çalışmalarda öğrenme katsayısının genellikle 0.2-0.4 arasındaki değerlerde kullanıldığı, bazı uygulamalarda ise 0.6-0.8 değerinin de başarılı sonuçlar ürettiği görülmektedir. Bu katsayının aldığı değer uygulamaya bağlı olarak değişiklik gösterebilmektedir. Bu çalışmada, programın açılış ayarlarındaki öğrenme katsayısı ile ağ eğitime başlanmış ve bu değer artırılması ve azaltılması yolu ile çeşitli değerler denenerek ağın performansı değerlendirilmiştir. Bu denemeler sonrasında, öğrenme katsayısının 0.80 olduğu modellerin diğerlerine göre daha az hata ürettiği görülmüştür.

Ağın eğitilmesi sırasında, bir iterasyondaki değişimin belirli bir oranı bir sonraki değişim miktarına eklenmektedir. Momentum katsayısı, eklenecek değişim miktarının oranını ifade etmektedir. Bu katsayı özellikle yerel çözümlere takılan ağların bir sıçrama ile daha iyi sonuçlar bulmasını sağlamak amacıyla önerilmiştir. Bu değer küçük olması yerel çözümlerden kurtulmayı zorlaştırabilmektedir. Çok büyük değerlerde ise tek bir çözüme ulaşmada sorunlar yaşanabilmektedir. Genellikle 0.6-0.8 arasında seçilmektedir. Burada geliştirilen modelde momentum katsayısı, yazılımın sabit bir değer vermesi nedeniyle, 0.5 olarak alınmıştır.

Ağırlık başlangıç değerleri, problemin çözümünün aranmaya başlandığı noktalardır ve genellikle -1.0 ile 1.0 arasında atanmaktadırlar. Bu çalışmada, nöronları birbirine bağlayan ağırlık değerlerinin ve eşik değer birimi ağırlıklarının başlangıç değerleri, her iterasyonda -1.0 ve 1.0 arasında rassal olarak atanmıştır.

#### 4. Öğrenme setinden örneklerin seçilmesi ve ağa gösterilmesi.

Ağın öğrenmeye başlaması ve öğrenme kuralına uygun olarak ağırlıkları değiştirmesi için ağa örnekler (Girdi/Çıktı) belirli bir düzeneğe göre gösterilir. Örnekler ağa sıralı ya da rassal olarak gösterilebilmektedirler. Burada ise örnekler rassal olarak ağa gösterilmiştir.

### 4.2 Yapay Sinir Ağı Modelinin Eğitilmesi ve Test Edilmesi

Ağın eğitimi sırasında, 1995 ile 2004 yılları arasında halka açılan şirketler büyüklüklerine göre iki gruba ayrılmışlardır. Büyüklük ölçütü olarak, şirketlerin halka açıldıkları zaman sahip oldukları varlıkların toplamı göz önünde bulundurulmuştur. 0-50 milyon \$ arasında toplam varlığa sahip olanlar birinci veri setini (A), 50 milyon \$'dan büyük toplam varlığa sahip olanlar ikinci veri setini (B) oluşturmaktadır. Buna göre, 165 halka açılan şirketin 104'ü A grubunda, 61'i B grubunda yer almaktadır. Oluşturulan bu iki veri seti için ayrı YSA modelleri geliştirilmiştir.

#### 4.2.1 Ağın Eğitimi

Ağın eğitiminde, örnek seçimi rasgele, kalibrasyon aralığı ise her 100 iterasyona göre ayarlanmıştır. Yani, ağa ilişkin grafikler her 100 iterasyonda bir güncellenerek ekrana yansıtılmıştır. Ağın eğitiminin durdurma ölçütü olarak belirli iterasyon sayıları kullanılmıştır. Genellikle, ağ çeşitli parametrelere göre denenirken, iterasyon sayısı 2500, 5000 veya 10000 olarak seçilmiştir.

Kullanılan yazılımın eğitim modülünde, ağ en iyi test setini bulmak için ağırlıkları otomatik olarak kaydetmektedir. Ağın çıktısı, aynı sayfa içerisinde gerçek  $\ln P1$  değeri, ağın ürettiği tahmini  $\ln P1$  değeri ve ağın ortalama hatası olmaktadır. Bu değerlere göre, ağın ortalama mutlak hatası ve gerçek değerlere karşı ağın tahmini değerlerinin grafiği Excel'de oluşturulmuştur. Eğer ağın ortalama hatası ve

ortalama mutlak hatası kabul edilebilir bir düzeyde ise, eğitilen ağın parametreleri, test verisine uygulanarak ağın gerçek performansı ölçülmüştür.

#### 4.2.2 Ağın Test Edilmesi

Ağın performansını test etmek için her iki (A ve B) veri setinin %20'si test verisi olarak ayrılmıştır. Burada amaç, ağın daha önce görmediği örnekler karşısındaki performansını ölçmektir. Eğitilen ağ parametreleri kullanılarak yeni örnekler üzerinde her iki model test edilmiştir. Yazılımın test modülünün çıktıları, yalnızca gerçek değer ile ağın ürettiği tahmini değerlerdir. Burada da performans ölçütü olarak ortalama mutlak hata göz önüne alınmıştır.

Yapay sinir ağı modellerinin geliştirilmesinde bu bölümde bahsedildiği gibi pek çok parametre rol oynamaktadır. Bu parametrelerin sezgisel olarak oluşturulması nedeniyle, ilk halka arzların ilk gün fiyat performanslarını tahmin edecek bir yapay sinir ağı modelinin geliştirilmesi aşamasında uygun model bulununcaya kadar çok sayıda başarısız model geliştirilmiştir. Bu modellerin bir kısmında ya ağın öğrenmesi gerçekleşmemiş ya da ağın performans ölçütlerinden biri olan ortalama mutlak hatası düşürülememiştir. Bazılarında ise, ağ verileri ezberlemiş olduğu için eğitim verilerinde yüksek performans sergilerken, test verilerinde hata oranları oldukça yüksek çıkmıştır. Bu başarısız modeller elenerek ilk halka arzların ilk gün fiyatlarını doğru tahmin eden nihai yapay sinir ağı modeli elde edilmiştir.

## 5 PERFORMANS DEĞERLENDİRME

Bu bölümde, ilk halka arzların ilk gün fiyatlarını tahmin etmesi için geliştirilen YSA modellerinin performansı değerlendirilmiştir ve çeşitli ölçütlere göre çoklu regresyon modelinin performansı ile karşılaştırılmıştır. Aynı zamanda, YSA modeli ile çoklu regresyon modelinin doğru tahmin yapma olasılıkları Bayes kuralına göre hesaplanıp karşılaştırılmıştır.

### 5.1 Performans Değerlendirme Ölçütleri

Geliştirilen YSA modellerinin performansı, eğitim ve test seti için ürettikleri tahmin değerlerinin ortalama mutlak hata ve istatistiksel bir ölçüt olan  $R^2$  değerleri, çoklu regresyon modeli ile kıyaslanarak incelenmiştir. Aynı zamanda hisse senedinin ilk gün fiyatına ilişkin ürettikleri dağılımların gerçeğe ne kadar yakın olduğu ve modellerin düşük fiyatlamayı belirleyebilme yetenekleri araştırılmıştır. Son olarak, modellerin düşük fiyatlamaları doğru bulma olasılıkları hesaplanmış ve buna göre modeller karşılaştırılmıştır.

Burada modellerin düşük fiyatlamaya göre birbirleri ile kıyaslanması sırasında, Habib ve Ljungqvist'in önerdiği şekilde, düşük fiyatlama için Tablo 11'deki formülasyon kullanılmıştır.

Tablo 11: Düşük Fiyatlamaya İlişkin Formülasyonlar

Tanım	Formül
Gerçekleşen Düşük Fiyatlama Oranı	$(P_1 - P_0) / P_0$
YSA Modelinin Tahmini Düşük Fiyatlama Oranı	$(P_{YSA} - P_0) / P_0$
Regresyon Modelinin Tahmini Düşük Fiyatlama Oranı	$(P_R - P_0) / P_0$
$P_0$ : Hisse senedinin ihraç eden şirket/aracı kurum tarafından belirlenen İHA fiyatı $P_1$ : Hisse senedinin ilk işlem gününün sonundaki kapanış fiyatı $P_{YSA}$ : YSA'nın tahmin ettiği $P_1$ fiyatı $P_R$ : Çoklu Doğrusal Regresyon Modelinin tahmin ettiği $P_1$ fiyatı	

YSA'nın tahmin değerleri ile gerçek değerler arasında fark olup olmadığını araştırmak için, "bu iki değerlerin ortalamaları arasında fark yoktur" sıfır hipotezi t-test ve Mann-Whitney testi ile test edilmiştir. Eğer YSA tahmin konusunda başarılı ise, bu testlerin sonucunda sıfır hipotezi reddedilmemelidir.

Buna ek olarak, yapay sinir ağı ile çoklu regresyon tekniğinin performansları karşılaştırılmıştır. Çoklu regresyon tekniği ile geliştirilen modelde, yapay sinir ağı tarafından kullanılan aynı girdi ve çıktı değişkenleri kullanılmıştır. Girdi değişkenleri bağımsız değişkenler olarak, çıktı ise bağımlı değişken olarak alınmıştır.

Çoklu regresyon ile YSA'nın performansı, ortalama mutlak hata ve  $R^2$  ölçütlerine göre karşılaştırılmıştır. Aynı zamanda, her iki modelin performansı, her modelin belirli bir güven düzeyinde düşük fiyatlamaya ilişkin yaptıkları doğru tahmin yüzdesine göre karşılaştırılmıştır. Bir başka deyişle, her iki yöntemle geliştirilen modellerin yaptıkları tahminin doğru olma olasılıkları hesaplanmıştır. Bu hesaplamalar, Bayes teoremine veya koşullu olasılık yöntemine göre yapılmıştır.

### 5.1.1 Çoklu Regresyon

Çoklu regresyon, bir bağımlı değişken üzerinde 1'den fazla bağımsız değişkenin etkisinin araştırıldığı durumlarda kullanılan parametrik bir yöntemdir. Burada amaç, çeşitli noktaların oluşturduğu saçılım diyagramlarının üzerine doğrusal bir cevap yüzeyinin uyumunun sağlanmasıdır. Bu cevap yüzeyini ifade eden denkleme çoklu regresyon denklemi denir.

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

Yukarıdaki denklemde,  $X$ 'ler bağımsız değişkenleri,  $Y$  ise bağımlı değişkeni simgelemektedir. Alt indis  $i$ , gözlem numarasıdır.  $\beta$ 'lar bilinmeyen regresyon katsayılarıdır. Çoklu regresyon, denklemde bulunan  $\beta_i$ 'leri tahminler.  $\beta$ , bilinmeyen gerçek (populasyon) parametreyi gösterir. Bu bilinmeyen parametreler, populasyon

seçilen örnekler üzerinden tahmin edilirler.  $\beta$ 'nin tahmini ise,  $b$  ile gösterilir.  $e_i$ ,  $i$ . sıradaki hata terimidir.

Regresyon denklemi birkaç farklı yöntemle çözülebilmektedir. En sık kullanılan yöntem, en küçük kareler yöntemidir. Bu yöntemde kareler toplamını minimum yapacak  $b$ 'ler hesaplanır. Çoklu regresyon analizinde bir bağımlı değişken ile  $n$  bağımsız değişkenin ilişkisi incelenir. Bu denklemin genel formu,

$$\hat{Y}_i = b_0 + b_1 X_{i1} + b_2 X_{i2} + \dots + b_n X_{in}$$

şeklinindedir. Burada  $b_0$ , regresyon düzleminin  $Y$  eksenini kestiği noktayı,  $b_i$ 'ler regresyon düzleminin  $X_i$  eksenleri ile olan eğimini gösterir. Bu katsayılara kısmi regresyon katsayıları denmektedir. Her bir kısmi regresyon katsayısı,  $i$ . değişkene, diğer değişkenlerin etkilerinin sabit tutulduğu durumdaki net etkiyi gösterir. Tahminlerde yapılan hatalar ise şu şekilde ifade edilir:

$$E_i = Y_i - \hat{Y}_i$$

Elde edilen modelin veriler üzerinde iyi uyum gösterip göstermediği  $R^2$  değeri ile ölçülür.  $R^2$ 'nin 1 olması mükemmel uyumu, 0 olması ise çok zayıf uyum olduğunu gösterir.  $R^2$  değeri aşağıdaki formül ile hesaplanmaktadır.

$$R^2 = 1 - \frac{SSE}{SS_{yy}}$$

Burada  $SSE = \sum (Y_{\text{gerçek}} - Y_{\text{tahmin}})^2$  ve  $SS_{yy} = \sum (Y_{\text{gerçek}} - \bar{Y})^2$  ile bulunmaktadır.

$Y_{\text{gerçek}}$ :  $Y$  bağımlı değişkenin aldığı gerçek değer,  $Y_{\text{tahmin}}$ :  $Y$  bağımlı değişkenin tahmini değeri,  $\bar{Y}$ :  $Y$  bağımlı değişkeninin aldığı gerçek değerlerin ortalamasıdır. Bu ölçüt, bu çalışmada geliştirilen YSA modeli ile regresyon modelinin performanslarını karşılaştırmada kullanılmıştır.



Regresyon modeli oluşturulurken yapılan katsayı hesaplamalarına burada değinilmeyecektir. Geliştirilen bir regresyon modelinin geçerli olabilmesi, modelin bazı varsayımları sağlamasına bağlıdır. Regresyon modelinin başlıca varsayımları şunlardır:

- i. Doğrusallık: Bağımlı değişken ile her bir bağımsız değişken arasında doğrusal bir ilişki olmalıdır.
- ii. Normallik: Hata terimi  $e$ 'nin dağılımı normaldir.
- iii. Sabit varyanslılık: Hata terimi  $e_i$ 'nin ya da bağımlı değişken  $Y$ 'nin varyansı her  $X_i$  bağımsız değişkeni için aynıdır.
- iv. Bağımsızlık: Hata terimi  $e$ 'nin değerleri arasında ilişki yoktur.

Doğrusallık varsayımı, "*Y ve X'ler arasında doğrusal ilişki yoktur*" sıfır hipotezine karşılık, "*En azından bir regresyon katsayısı sıfıra eşit değildir*" alternatif hipotezinin ANOVA testi ile test edilebilir. ANOVA'da hesaplanan F test istatistiği anlamlı ise, bir sonraki adım çoklu doğrusal regresyon modeline bireysel katkıları analiz etmektir. Bu analiz her katsayıya t-test uygulanarak gerçekleştirilmektedir.

Normallik varsayımı, regresyon modelinden elde edilen hata terimlerinin normal dağılımlı olması gerektiğini ifade eder. Normallik varsayımı, verilerin histogramı veya normal olasılık kâğıtlarının çizilmesi ile test edilebileceği gibi, Kolmogorov-Smirnov gibi test istatistikleri yardımıyla da test edilebilmektedir. Levine vd. (1997), regresyon analizinin normallik varsayımından sapmalara karşı oldukça dirençli bir istatistiksel teknik olduğunu ifade etmektedir. Bu, normallik varsayımının sağlanamadığı bazı durumlarda bile regresyon modelinin geçerli tahminler yapabileceği anlamına gelmektedir.

Sabit varyanslılık, her  $X$ 'e karşılık gelen  $Y$  değerlerinin dağılımlarının eşit olması anlamına gelir. Bu varsayım, basitçe  $X$ 'lere karşılık  $\hat{Y}$  tahmin değerlerinin veya  $e$  hata terimlerinin saçılım grafiği çizilerek test edilebilir.

Bağımsızlık varsayımı, ardışık gözlemlerin birbirleri ile ilişki olmaması gerektiğini ifade eder. İlişki bulunması halinde gözlemler arasında seri korelasyonun

olduğu söylenmektedir. Seri korelasyon, Durbin-Watson test istatistiği kullanılarak tespit edilebilmektedir. Bu test istatistiğinin 2'ye eşit ya da 2 civarında bir değere sahip olması seri korelasyonun bulunmadığını göstermektedir (Keller ve Warrack, 2003; 681).

Çoklu regresyon konusunun temel problemlerinden biri, en büyük R veya  $R^2$ 'yi veren değişken setinin seçimidir (Lubis, 2001; 53). R, bağımsız değişkenlerin doğrusal kombinasyonunu kullanarak Y bağımlı değişkeni ile  $\hat{Y}$  tahmin değerleri arasındaki korelasyonun bir ifadesidir.  $R^2$  ise, bağımlı değişken içindeki varyasyonun bağımsız değişkenler yoluyla ne kadarının açıklanabildiğini göstermektedir. Bu nedenle bağımsız değişkenler seçilirken bağımsız değişken ile yüksek korelasyona sahip olmaları istenir. Fakat bağımsız değişkenlerin, birbiri ile de korelasyonlu olmamaları gerekmektedir. Çünkü bu durum çoklu doğrusal bağlantı adı verilen bir başka problemi ortaya çıkarır.

Çoklu doğrusal bağlantı, bağımsız değişkenlerin aralarında yüksek korelasyon olması durumunda ortaya çıkar. Çoklu doğrusal bağlantı durumunu ölçmek için her değişkenin varyans şişirme faktörü (VIF-Variance Inflation Factor) adı verilen bir ölçüt bulunmaktadır. Bu değer  $1/(1-R^{2*})$  ile bulunmaktadır. Buradaki  $R^{2*}$ , ilgili değişkenin bağımlı olarak alınıp diğer bağımsız değişkenlerle bir regresyon modeli kurulduğunda elde edilecek olan açıklanma yüzdesidir. Büyük veri setleri için 10 veya daha fazla bir VIF değeri, küçük veri setleri için ise, 5 veya daha fazla VIF değerleri çoklu doğrusal bağlantıyı işaret etmektedir (Ergün, 1995; 158). Benzer şekilde, korelasyon matrisinden öz değerlerin toplamı modeldeki bağımsız değişken sayısına eşittir ve bu değerlerin sifıra yakın olması da çoklu doğrusal bağlantının olduğunu göstermektedir.

Çoklu regresyon modelinde genel olarak değişken sayısını çok tutma yönünde bir eğilim vardır. Bunun sebebi modele ne kadar değişken eklenirse, bu eklemenin modelin R veya  $R^2$ 'sinde bir artışa yol açmasıdır. Fakat birbiriyle korelasyonu düşük, bağımlı değişkenle korelasyonu yüksek olan çok fazla değişkeni bulmak zordur. Bu

yüzden, beş veya altı değişkenli modellere daha fazla değişken eklemek nadiren modelin  $R$  veya  $R^2$ 'sine gerçekten etki etmektedir (Lubis, 2001; 55).

Açıklanması gereken bir başka nokta ise bağımsız değişken sayısının gözlemlerin sayısına yaklaştıkça  $R$  veya  $R^2$  de artış olması durumudur. Az sayıda bağımsız değişkeni olan modellerde böyle bir sakınca ortaya çıkmaktadır. Beş veya altı bağımsız değişkenli ve yüzden fazla gözleme sahip modellerde böyle bir sorunla karşılaşmamaktadır (Keller ve Warrack, 2003; 662).

### 5.1.2 Koşullu Olasılıklar

Bayes Teoremi, olasılıkların içinde bulunduğu ortama bağlı olduğunu söyler. Bir koşullu olasılık,  $X$  olayı verildiğinde  $Y$ 'nin gerçekleşme olasılığı ya da  $P(Y/X)$  şeklinde ifade edilir. Bunun için öncelikle, ilgili ortam içerisinde kolaylıkla tanımlanacak bir şeyin belirlenmesi gerekmektedir. Her bir hisse senedinin ilk gün sonunda belirli bir fiyata ulaşma olasılığını hesaplamak zordur. Bunun yerine, hisse senedinin kaç kere yüksek getiri sağladığı, yani düşük fiyatlandığı ile ilgili olasılıklar hesaplanmıştır.

Soru şudur:

Geçmişteki düşük fiyatlamaların sayısı verildiğinde, her bir modelin düşük fiyatlamayı doğru tahmin etme olasılığı nedir?

Yukarıdaki sorunun cevabı,

*$P(\text{Tahmini düşük fiyatlamamanın doğru olması} / \text{Gerçek düşük fiyatlama bilgisi})$*

koşullu olasılığı ile bulunmuştur. Bu koşullu olasılık, Bayes teoreminin matematiksel formülü yerine, Excel'in çalışma sayfasında tanımlanan basit bir yöntem ile hesaplanmıştır.

Bunun için, Excel'in çalışma sayfası kullanılarak, orijinal (1995–2004 yılları arasındaki İHA'lardan) verilerden gerçek düşük fiyatlama sayısı hesaplanmıştır. Düşük fiyatlama sayısı, "Eğer(hisse senedinin getirisi>0;1;0)" mantıksal fonksiyonu kullanılarak belirlenmiştir. Fonksiyon, eğer hisse senedi düşük fiyatlanmış ise 1, aşırı fiyatlanmış ise 0 yaratmaktadır. Bu formülün uygulanmasından elde edilen sonuçların toplamı ile düşük fiyatlanmış İHA sayısı bulunmuştur. Aynı yöntem kullanılarak, YSA ve çoklu regresyon modellerinin test verileri üzerinden düşük fiyatlanmış hisselerin doğru tahmin sayıları bulunmuştur. Her bir modelin koşullu olasılığı ise, modelden elde edilen düşük fiyatlama sayısının (yüzdesinin), gerçek düşük fiyatlama sayısına (yüzdesine) oranlanması ile hesaplanmıştır.

## 5.2 YSA Modelinin A Seti (N=104) Üzerindeki Performansı

Toplam varlıklarına göre küçük olarak sınıflandırılan şirketlerden oluşan A veri seti, eğitim ve test seti olarak ikiye ayrılmıştır. 104 verinin yaklaşık %80'i yani 82 veri eğitim seti, geriye kalan 22 veri ise test seti olarak kullanılmıştır.

Tablo 12: YSA modeline gösterilen girdilerin özet istatistikleri (A seti)

	Ortalama	Std. Sapma	Korrelasyon
İNDEKS	-0,0004	0,0355	-0,069
ARZORANI	29,6582	21,0014	-0,563
LNHASILA	15,2195	1,0905	0,570
ORTSAT	-	-	-0,094
SERART	-	-	0,131
LNYAS	2,2374	1,0335	0,570
SEKTOR	-	-	-0,365
LNVARLIK	15,5630	2,4296	0,267
BORCVARL	0,3546	0,2625	0,399
KSAHIP	-	-	-0,075
BSAHIP	-	-	0,301
BLOKYTRM	-	-	0,224
ARACIKRM	-	-	-0,426
KRIZ	-	-	0,111

A setinin eğitim verileri ile ağırlar eğitildikten sonra, 14 girdi birimi ve tek ara katmanı olan üç katmanlı ileri beslemeli ağ yapısı en iyi YSA modeli olarak bulunmuştur. Ağlarda kullanılan girdi değişkenlerine ilişkin özet istatistikler Tablo 12’de gösterilmiştir. LNP1 çıktı değişkeni ile ARZORANI, LNHASILA, LNYAS, SEKTOR, BORCVARL ve ARACIKRM değişkenleri arasında orta derecede ilişki bulunurken, lnP1’in diğer girdiler ile zayıf ilişkisi olduğu gözlenmektedir.

A setinde yer alan İHA’lara ilişkin gerçek  $P_0$  ve  $P_1$  değerlerinin dağılışı Tablo 13’te verilmiştir. Gerçek  $P_0$  ve  $P_1$  değerlerinin ortalamaları arasındaki fark, tablodan da görüldüğü gibi, İHA’ların düşük fiyatlandırıldığını göstermektedir. Bu sonuç, aynı çalışma alanında daha önce yapılan araştırma sonuçları ile tutarlılık göstermektedir.

Tablo 13: A seti için gerçek  $P_0$  ve  $P_1$  değerlerinin dağılımına ilişkin istatistikler

Yeni Kuruş	Ortalama	Medyan	Std. Sapma
P1: İlk işlem günü sonundaki İHA'nın kapanış değeri	12,12	8,45	15,51
P0: İHA fiyatı	11,31	7,70	15,06

Küçük firmalardan oluşan A veri seti için çok sayıda YSA modeli eğitime çalışılmıştır. Geliştirilen YSA’ların performansı ara katmandaki nöron sayısı, öğrenme katsayısı ve başlangıç değerlerine göre farklılıklar gösterdiğinden pek çok deneme başarısız olmuştur. Bu başarısız modeller elenmiş ve kalan modeller içerisinde A seti için en iyi performans gösteren bir YSA modeli elde edilmiştir. Bu modele ilişkin parametreler Tablo 14’te verilmiştir.

Tablo 14: En iyi YSA modelinin parametreleri

Parametreler	Tanımı / Değeri
Ağ mimarisi	İleri beslemeli
Öğrenme stratejisi	Öğretmenli öğrenme
Öğrenme algoritması	Geriye yayma algoritması
Eğitim/test verilerinin sayısı	82/22
Normalizasyon fonksiyonu	Logaritmik
Ara katman geçiş fonksiyonu	Hiperbolik tanjant
Ara katmandaki nöron sayısı	35
Öğrenme katsayısı	0.80
Momentum katsayısı	0.5
İterasyon sayısı	2500
Eğitim seti ortalama mutlak hata	0.100207
Test seti ortalama mutlak hata	0.083389
Ağın R <sup>2</sup> değeri	0.9897
Ağın doğru yaptığı tahmin yüzdesi (%10'a göre)	%68
Ağın düşük fiyatlamayı doğru tahmin etme olasılığı	%53.3

Bu model, üç katmanlı bir ağ yapısına sahiptir. Girdi katmanında 14 girdi birimi, ara katmanda 35 nöron ve çıktı katmanında 1 çıktı birimi bulunmaktadır. Bu işlem birimleri birbirleri ile tam bağlantılıdır. Bu birimler arasındaki bağlantıların ağırlık değerleri Ek 1'de verilmiştir.

Bu modelin ürettiği fiyat tahminleri ile gerçek fiyatlar arasında farklılık olup olmadığını test etmek için, t-test ve Mann-Whitney testi uygulanmıştır. Bu iki test ile aşağıdaki sıfır hipotezi test edilmiştir.

H<sub>0</sub>: Küçük şirketlerin İHA'larının piyasadaki ilk gün sonundaki kapanış fiyatları ile YSA'nın tahmin ettiği fiyatlar arasında fark yoktur

Tablo 15: T-testinin sonuçları (A seti)

Grup İstatistikleri				
GRUP	N	Ortalama	Std. Sapma	Ortalamanın Std. Hatası
A SETİ GERCEK DEĞER	104	12122,32	15513,0430	1521,1790
YSA TAHMİN	104	9064,0000	4474,9818	438,8081

Bağımsız Örnekler Testi

		Sabit varyans için Levene Testi		t-test						
		F	p-değeri	t	sd	p-değeri (çift yönlü)	Ortalamaların farkı	Standart hataların farkı	95% Güven Aralığı	
									Alt limit	Üst limit
A SETİ	Eşit varyanslar	21,91	,000	1,932	206	,055	3058,3173	1583,2050	-63,0453	6179,6799
	Eşit olmayan varyanslar			1,932	120,02	,056	3058,3173	1583,2050	-76,3121	6192,9467

Tablo 15'teki Levene Testi, karşılaştırılan iki grubun varyanslarının ortak olup olmadığını kontrol eder. Eğer Levene testinden %5'ten büyük p-değeri elde edilirse, bu durumda eşit varyans söz konusu olmaktadır ve eşit varyanslar satırındaki ilgili t-test değerlerine bakılmalıdır.

Levene Testi, %5 önem seviyesinde iki grubun varyanslarının eşit olmadığını göstermektedir. T-teste göre ise,  $H_0$  reddedilememiştir, yani iki dağılımın ortalamaları arasında fark yoktur.

Aynı şekilde, Mann-Whitney U Testi ile test edildiğinde de  $H_0$  hipotezi reddedilememiştir (Tablo 16). Burada ikinci bir testin yapılmasının nedeni, verilerin normal dağılım varsayımından sapma göstermeleridir. Her ne kadar veriler üzerinde normalizasyon fonksiyonları uygulansa da (örn. LnP1),  $H_0$  hipotezi konusunda şüphe bırakmamak için iki test birlikte değerlendirilmiştir.

Tablo 16: Mann-Whitney U testinin sonuçları (A seti)

**Sıra Sayıları**

GRUP	N	Sıra sayıları ortalaması	Sıra Sayıları Toplamı
A seti GERÇEK DEĞER	104	101,41	10546,50
YSA TAHMİN	104	107,59	11189,50
Toplam	208		

**Test İstatistikleri**

	A seti
Mann-Whitney U	5086,500
Wilcoxon W	10546,500
Z	-,741
p-değeri (2-yönlü)	,459

Bu iki test sonucu, YSA modelinin yaptığı tahminlerin gerçek değerlerden farklı olmadığını, aralarındaki farkların ise tesadüflükten kaynaklandığını ifade etmektedir. Buna göre, geliştirilen YSA modeli halka arzların ilk gün fiyat performanslarını tahmin edebilecek yeteneğe sahiptir.



### 5.2.1 Çoklu Regresyon Sonuçları

Burada, küçük şirketler için geliştirilen YSA modeli, aynı veri seti kullanılarak elde edilen çoklu regresyon modeli ile karşılaştırılmıştır. Regresyon modelinin girdi değişkenleri Tablo 12’de gösterilmiştir. Aynı girdi değişkenlerinin bağımsız değişkenler şeklinde kullanılarak oluşturulan regresyon modelinin sonuçları Tablo 17’de verilmiştir.

Modelin  $R^2$  değeri %76.9 bulunmuştur, yani bağımsız değişkenler LnPI’deki değişimin %76.9’unu açıklayabilmektedirler (Tablo 17(a)). Aynı tabloda verilen Durbin-Watson test istatistiğinin değeri 2.287’dir. Bu değer 2 civarında değerler alması gözlem değerleri arasında seri korelasyon olmadığı anlamına gelmektedir. Elde edilen test istatistiğine göre gözlenen değerler arasında seri korelasyon bulunmamaktadır. Tablo 17(b)’de verilen ANOVA tablosuna göre, elde edilen F değeri anlamlıdır, yani bağımsız değişkenlerden en az birinin katsayısı sıfırdan farklı ve bireysel olarak modele katkısı anlamlıdır. Tablo 17(c)’de modelin katsayıları ve t-istatistikleri verilmiştir. Buna göre, ARZORANI, LNHASILA, SERART, LNYAS, SEKTOR, LNVARLIK, ARACIKRM ve KRIZ değişkenlerinin bireysel olarak modele katkılarının %5 güven düzeyinde anlamlı olduğu görülmektedir.

Tablo 17: Çoklu regresyon modelinin sonuçları (A seti)

(a)

MODEL ÇIKTIŞI

Model	R	R <sup>2</sup>	Düzeltilmiş R <sup>2</sup>	Tahminin standart hatası	Durbin-Watson
1	,877 <sup>a</sup>	,769	,721	,5956	2,287

a. Bağımsız Değişkenler: (Sabit), KRIZ, BLOKYTRM, SERART, INDEKS, BSAHIP, SEKTOR, LNVARLIK, LNYAS, LNHASILA, KSAHIP, ARACIKRM, BORCVARL, ARZORANI, ORTSAT

b. Bağımlı Değişken: LNP1

(b)

ANOVA


Model		Hata Kareleri	s.d.	Ortalama Karese Hata	F	p-değeri
1	Regression	79,157	14	5,654	15,938	,000
	Hata	23,768	67	,355		
	Toplam	102,925	81			

(c)

Katsayılar

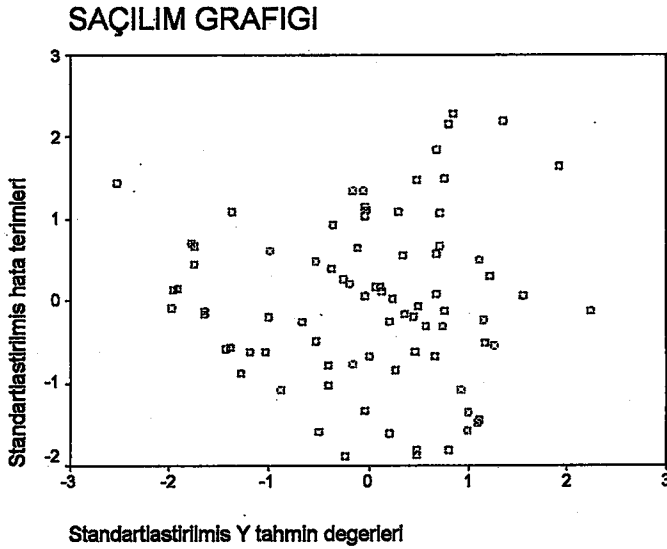
Model		Katsayılar		Standartlaştırılmış Katsayılar	t	p-değeri	Çoklu Bağlantı İstatistikleri	
		B	Std. Hata	Beta			Tolerans	VIF
1	(Sabit)	5,709	1,338		4,266	,000		
	İNDEKS	1,205	2,346	,035	,513	,609	,728	1,373
	ARZORANI	-2,09E-02	,005	-,423	-4,603	,000	,409	2,447
	LNHASILA	,334	,073	,321	4,551	,000	,693	1,443
	ORTSAT	-,254	,231	-,108	-1,098	,276	,354	2,824
	SERART	-,607	,256	-,228	-2,371	,021	,371	2,693
	LNYAS	,194	,095	,181	2,046	,045	,440	2,272
	SEKTOR	-6,29E-02	,030	-,151	-2,108	,039	,674	1,484
	LNVARLIK	-7,02E-02	,033	-,148	-2,160	,034	,733	1,364
	BORCVARL	,103	,343	,024	,302	,764	,526	1,902
	KSAHIP	,176	,182	,072	,966	,338	,613	1,631
	BSAHIP	,163	,167	,069	,979	,331	,690	1,449
	BLOKYTRM	,163	,148	,070	1,102	,274	,848	1,179
	ARACIKRM	-,513	,215	-,181	-2,387	,020	,596	1,678
	KRIZ	,363	,173	,137	2,106	,039	,816	1,225

Tablo 17(c)'de verilen VIF değerleri 1 civarında değerlere sahiptir. Bunlardan hiçbiri 10 değerini aşmamaktadır. Öyleyse, bağımsız değişkenler arasında çoklu doğrusal bağlantı problemi bulunmamaktadır.



Şekil 19: Normal Olasılık Grafiği (A seti)

Şekil 19'da, normal olasılık grafiğinde hata terimlerinin bir doğru üzerindeymiş gibi bir dağılım göstermeleri, bu verilerin normal dağılımlı olduğunu ifade etmektedir. Şekil 20'deki saçılım grafiğinden de, verilerin rasgele bir dağılım gösterdiği görülmektedir. Buna göre, hata terimlerinin varyansı sabittir.



Şekil 20: Y tahminlerinin hata terimlerine karşı saçılım grafiği (A seti)

Tablo 18: YSA ve çoklu regresyon modelinin karşılaştırılması (A seti)

Performans kriterleri	YSA	Çoklu Regresyon
Ortalama mutlak hata	0.083389	0.10693
R <sup>2</sup> değeri	0.9897	0.7690
Ağın doğru yaptığı tahmin yüzdesi (%10'a göre)	%68	%64

A veri seti için elde edilen regresyon modeli ile YSA modeli, hiç görmedikleri örneklerden oluşan test seti üzerindeki tahmin performanslarına göre Tablo 18'de karşılaştırılmıştır. YSA modelinin yaptığı tahminlerden elde edilen ortalama mutlak hata %8.34 iken, çoklu regresyonda bu değer %10.69 olarak bulunmuştur. YSA modelinin R<sup>2</sup> değeri, regresyon modelininkinden daha yüksektir. %10'nun altındaki hata değerine sahip tahminlerin doğru olanlarının yüzdesi de bir başka ölçüt olarak değerlendirilmiştir. Tüm bu ölçütlere göre, küçük şirketlerin ilk halka arzlarının fiyat performanslarını tahmin etmede YSA'nın regresyona göre daha iyi bir model olduğu söylenebilmektedir.

Ek 2'de bulunan A setine ilişkin performans grafikleri de regresyon modeline kıyasla YSA'nın tahminlerinin gerçek değerlere daha yakın olduğunu açıkça göstermektedir.

## 5.2.2 Koşullu Olasılıkların Hesaplanması

1995-2004 yılları arasında halka açılan küçük şirketlerin test verilerinden, ilk olarak düşük fiyatlamaya ilişkin gerçek olasılıklar hesaplanmıştır. Tablo 19, bu olasılıkları göstermektedir.

Tablo 19: Küçük şirketler için gerçek fiyatlama olasılıkları (A seti test verileri)

	Frekans	Olasılık
Düşük Fiyatlama	13	0.591909
Aşırı Fiyatlama	9	0.409091
Toplam	22	1.000000

Tablo 20: YSA modelinin tahmin performansları (A seti test verileri)

	Frekans	Olasılık
Yanlış Tahmin	7	0.318182
Düşük Fiyatlama	8	0.363636
Aşırı Fiyatlama	7	0.318182
Toplam	22	1.000000

Tablo 21: Regresyon modelinin tahmin performansları (A seti test verileri)

	Frekans	Olasılık
Yanlış Tahmin	10	0.454545
Düşük Fiyatlama	1	0.045455
Aşırı Fiyatlama	11	0.500000
Toplam	22	1.000000

Tablo 20 ve 21’de her iki model için test verileri üzerinde yaptıkları tahminlerin doğru olma olasılıkları bulunmuştur. Bu olasılıklar elde edilirken Excel’in “Eğer(...;...;...)” mantıksal fonksiyonu kullanılmıştır. Buradaki ilk ölçüt, modelin ürettiği tahminlerin %10 hata payından daha düşük hata ile tahmin yapmış olmasıdır. İkinci olarak, %10 hata payından düşük tahminler içinden kaçının düşük fiyatlamayı doğru tahmin ettiği hesaplanmıştır.

Yukarıdaki bilgiler kullanılarak, *P(Tahmini düşük fiyatlamamanın doğru olması / Gerçek düşük fiyatlama bilgisi)* koşullu olasılığı her iki model için hesaplanmıştır.

$$P(\text{YSA modelinin düşük fiyatlamaya ilişkin tahminin doğru olması} / \text{Gerçek düşük fiyatlama bilgisi}) = 0.363636 / 0.591909 = 0.615385$$

$$P(\text{Regresyon modelinin düşük fiyatlamaya ilişkin tahminin doğru olması} / \text{Gerçek düşük fiyatlama bilgisi}) = 0.045455 / 0.591909 = 0.076923$$

YSA ve regresyon için hesaplanan koşullu olasılıkların değerine göre, YSA modelinin regresyondan daha doğru tahminler yapabileceği açıkça görülmektedir.

### 5.3 YSA Modelinin B Seti (N=61) Üzerindeki Performansı

A setinde olduğu gibi, toplam varlıklarına göre büyük olan şirketlerden oluşan B veri setinin de %20'si test seti olarak ayrılmıştır. Bu durumda, 50 eğitim verisi eğitim sırasında, 11'i ise performans ölçmek için kullanılmıştır. A seti üzerinde oluşturulan modelin aynı girdi değişkenleri, B seti üzerinden bir YSA modeli geliştirmede de kullanılmıştır. B. seti için geliştirilen ağlara gösterilen girdi değişkenlerine ilişkin özet istatistikler Tablo 22'de gösterilmiştir. Aynı zamanda tablonun en solundaki sütunda her bir girdi değişkeni ile çıktı değişkeni ( $LnP_1$ ) arasındaki korelasyon değerleri bulunmaktadır. Küçük şirketler açısından değerlendirildiğinde, söz konusu girdilerin ilk halka arz fiyatı ile zayıf ilişkili olduğu görülmektedir.

Tablo 22: YSA modeline gösterilen girdilerin özet istatistikleri (B seti)

GİRDİLER	ORTALAMA	STD. SAPMA	KORELASYON
İNDEKS	-3,40E-03	3,30E-02	0,161
ARZORANI	21,8988	13,9731	-0,29
LNHASILA	16,8759	1,2369	0,158
ORTSAT	0,54	0,5	0,093
SERART	0,7	0,46	-0,031
LNYSAS	2,4884	0,9658	0,261
SEKTÖR	6,1311	2,4798	-0,301
LNVARLIK	18,937	1,0903	-0,065
BORCVARL	0,532	0,2865	0,136
KSAHIP	0,84	0,37	0,068
BSAHIP	0,2	0,4	0,068
BLOKYTRM	0,51	0,5	0,091
ARACIKRM	0,34	0,48	-0,181
KRIZ	0,33	0,47	0,212

B setinde yer alan İHA'lara ilişkin gerçek  $P_0$  ve  $P_1$  değerlerinin dağılışı da Tablo 23'te verilmiştir. Gerçek  $P_0$  ve  $P_1$  değerlerinin ortalamaları arasındaki fark, tablodan da görüldüğü gibi, İHA'ların düşük fiyatlandırıldığını göstermektedir. Bu sonuç, aynı çalışma alanında daha önce yapılan araştırma sonuçları ile tutarlılık göstermektedir. Burada ele alınan İHA'lar büyük şirketlere ait örneklerdir. B

setindeki verilerin dağılışı sağa çarpıktır (Medyan < Ortalama). Bu durumda düşük fiyatlama oranı hesaplanırken bu örnek için medyan değerlerini merkezi değerler olarak seçmek daha sağlıklı sonuçlar verebilir.

Tablo 23: Gerçek  $P_0$  ve  $P_1$  değerlerinin dağılımına ilişkin istatistikler (B seti)

(Yeni Kuruş)	Ortalama	Medyan	Std. Sapma
P1: İlk işlem günü sonundaki İHA'nın kapanış değeri	13,09	6,80	14,44
P0: İHA fiyatı	12,13	7,00	12,80

B seti için uygun model bulununcaya kadar çok sayıda denemeler gerçekleştirilmiştir ve nihayetinde, İHA'ların fiyatlarının tahminlenmesinde kullanılabilir en iyi YSA modeli elde edilmiştir. Bu modelin parametreleri Tablo 24'te verilmiştir.

Tablo 24 Büyük şirketler için geliştirilen YSA modeli (B seti)

Parametreler	Tanımı / Değeri
Ağ mimarisi	İleri beslemeli
Öğrenme stratejisi	Öğretmenli öğrenme
Öğrenme algoritması	Geriye yayma algoritması
Eğitim/test verilerinin sayısı	50/11
Normalizasyon fonksiyonu	Logaritmik
Ara katman geçiş fonksiyonu	Hiperbolik tanjant
Ara katmandaki nöron sayısı	35
Öğrenme katsayısı	0.80
Momentum katsayısı	0.5
İterasyon sayısı	2500
Eğitim seti ortalama mutlak hata	0.090773
Test seti ortalama mutlak hata	0.074302
Ağın $R^2$ değeri	0.993247
Ağın doğru yaptığı tahmin yüzdesi (%10'a göre)	%82
Ağın düşük fiyatlamayı doğru tahmin etme olasılığı	%100



Bu model, üç katmanlı bir ağ yapısına sahiptir. Girdi katmanında 14 girdi birimi, ara katmanda 35 nöron ve çıktı katmanında 1 çıktı birimi bulunmaktadır ve bu işlem birimleri birbirleri ile tam bağlantılıdır. Bu birimler arasındaki bağlantıların ağırlıkları Ek 3’de verilmiştir. Bu modelin dışında B veri setine ilişkin, nihai YSA modeli kadar iyi performans gösteren 9 model daha bulunmuştur. Burada, bu 9 modelin ayrıntısına girilmemiştir. Ek4’te, özet birkaç parametre değeri ile bu modeller tablo halinde gösterilmiştir.

Geliştirilen YSA modelin ürettiği fiyat tahminleri ile gerçek fiyatlar arasında farklılık olup olmadığını test etmek için, küçük şirketler için yapılan testlerde bahsedilen nedenlerden dolayı, her iki test burada da uygulanmıştır. Aşağıda test edilen sıfır hipotezi verilmiştir.

Ho: Büyük şirketlerin İHA’larının piyasadaki ilk gün sonundaki kapanış fiyatları ile YSA’nın tahmin ettiği fiyatlar arasında fark yoktur

Tablo 25: T-testinin sonuçları (B seti)

Grup İstatistikleri

GRUP	N	Ortalama	Std. Sapma	Ortalamanın Std. Hatası
B SETİ GERÇEK DEĞER	61	13091,39	14443,8377	1849,3439
YSA TAHMİN	61	13678,56	13428,0255	1719,2825

Bağımsız Örnek Testi

		Sabit Varyans İçin Levene Testi		t-testi					Farkın 95% Güven Aralığı	
		F	p-değeri	t	s.d.	p-değeri (2-yönlü)	Ortalamaların farkı	Farkın Std. Hatası	Alt limit	Üst limit
B SETİ	Eşit varyanslar	,424	,516	-,233	120	,817	-587,1639	2525,0753	-5586,64	4412,3094
	Eşit olmayan varyanslar			-,233	119,37	,817	-587,1639	2525,0753	-5586,91	4412,5792

Tablo 26: Mann-Whitney U testinin sonuçları (B seti)

Sıra Sayıları

GRUP	N	Sıra sayılarının ortalaması	Sıra sayıları toplamı
B SETİ GERÇEK DEĞER	61	57,44	3504,00
YSA TAHMİN	61	65,56	3999,00
Toplam	122		

Test İstatistikleri

	B SETİ
Mann-Whitney U	1613,000
Wilcoxon W	3504,000
Z	-1,267
p-değeri (2-yönlü)	,205

Her iki testin sonucunda elde edilen p-değerleri %5'ten büyük oldukları için  $H_0$  hipotezi reddedilememiştir. Buna göre, geliştirilen YSA modeli büyük şirketlerin halka arzlarının ilk gün fiyat performanslarını tahmin edebilecek yeteneğe sahiptir.

### 5.3.1 Çoklu Regresyon Sonuçları

Büyük şirketler için oluşturulan çoklu regresyon modelinin girdi değişkenleri Tablo 22’de gösterilmiştir. YSA modelindeki girdi değişkenleri burada bağımsız değişkenler şeklinde kullanılarak regresyon analizi gerçekleştirilmiştir. Bu modelin sonuçları Tablo 27’de görülmektedir.

Modelin  $R^2$  değeri %52.5 olarak bulunmuştur, yani bağımsız değişkenler  $\ln P1$ ’deki değişimin %52.5’ini açıklayabilmektedirler (Tablo 27(a)). Bu modelin Durbin-Watson test istatistiğinin değeri 2.527’dir. Durbin-Watson’a göre, elde edilen test istatistiğine göre gözlenen değerler arasında önemsiz derecede seri korelasyon bulunmaktadır. ANOVA tablosunda görüldüğü gibi, elde edilen F istatistiğinin p-değeri 0.007 bulunmuştur. Bağımsız değişkenlerden en az birinin katsayısı sıfırdan farklı ve bireysel olarak modele katkısı anlamlıdır. Tablo 27(c)’de modelin katsayıları ve t-istatistikleri verilmiştir. Buna göre, büyük şirketler açısından ARZORANI, LNHASILA, LNVARLIK ve BORCVARL değişkenlerinin bireysel olarak modele katkılarının %5 güven düzeyinde anlamlı olduğu görülmektedir.

Tablo 27(c)’de verilen VIF değerlerinin 10’dan küçük olması, bağımsız değişkenler arasında çoklu doğrusal bağlantı problemi bulunmadığını göstermektedir.

Tablo 27: Çoklu regresyon modeli sonuçları (B seti)

(a)

MODELİN ÇIKTIŞI

Model	R	R <sup>2</sup>	Düzeltilmiş R <sup>2</sup>	Tahminin Standart Hatası	Durbin-Watson
1	,725 <sup>a</sup>	,525	,335	,8051	2,527

a. Bağımsız Değişkenler: (Sabit), KRIZ, ARACIKRM, BORCVARL, SERART, BLOKYTRM, SEKTOR, INDEKS, LNHASILA, BSAHIP, LNYAS, ARZORANI, ORTSAT, KSAHIP, LNVARLIK

b. Bağımlı Değişken: LNP1

(b)

ANOVA

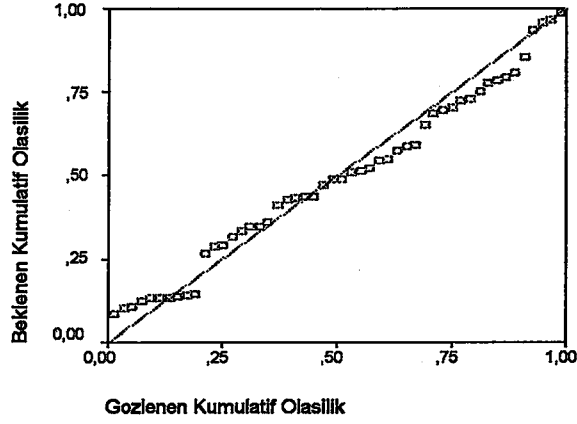
Model	Hata Kareleri	s.d	Ortalama Karesele Hata	F	p-değeri
1 Regresyon	25,072	14	1,791	2,763	,007
Hata	22,687	35	,648		
Toplam	47,759	49			

(c)

Katsayılar

Model		Katsayılar		Standart astırılmış Katsayılar	t	p-değeri	Çoklu Bağlantı İstatistikleri	
		B	Std. Sapma	Beta			Tolerans	VIF
1	(Sabit)	11,311	2,426		4,663	,000		
	İNDEKS	,152	3,790	,005	,040	,968	,801	1,248
	ARZORANI	-5,00E-02	,015	-,629	-3,390	,002	,394	2,538
	LNHASILA	,707	,183	,879	3,866	,000	,263	3,809
	ORTSAT	,180	,340	,092	,530	,599	,451	2,219
	SERART	,285	,352	,131	,808	,425	,518	1,932
	LNYAS	,153	,153	,152	1,001	,324	,588	1,701
	SEKTOR	-2,56E-02	,061	-,063	-,422	,676	,617	1,620
	LNVARLIK	-,796	,207	-,918	-3,840	,000	,237	4,212
	BORCVARL	1,728	,524	,517	3,295	,002	,551	1,815
	KSAHIP	,298	,476	,117	,627	,535	,388	2,575
	BSAHIP	,334	,459	,131	,727	,472	,416	2,403
	BLOKYTRM	,102	,255	,052	,399	,693	,803	1,245
	ARACIKRM	,396	,319	,192	1,240	,223	,566	1,766
	KRIZ	8,406E-03	,339	,004	,025	,980	,537	1,862


Standartlaştırılmış Hata Terimleri için  
Normal Olasılık Grafiği



Şekil 21: Normal Olasılık Grafiği (B seti)

Şekil 21’de, normal olasılık grafiğinde hafif sapmalar görünse de  $e$  hata terimi yaklaşık olarak normal dağılıma sahiptir. Şekil 22’deki saçılım grafiğinden görüldüğü gibi, veriler rasgele bir dağılım göstermektedir. Buna göre, model sabit varyanslılık varsayımını sağlamaktadır.

SACILIM GRAFIGI



Şekil 22: Y tahminlerinin hata terimlerine karşı saçılım grafiği (B seti)

Tablo 28: YSA ve çoklu regresyon modelinin karşılaştırılması (B seti)

Performans kriterleri	YSA	Çoklu Regresyon
Ortalama mutlak hata	0.090773	0.09577
R <sup>2</sup> değeri	0.993247	0.525
Ağın doğru yaptığı tahmin yüzdesi (%10'a göre)	%82	%55

Büyük şirketler için elde edilen regresyon modeli ile YSA modelinin performansları Tablo 28'de karşılaştırılmıştır. YSA modelinin ortalama mutlak hatası %9.08 iken, çoklu regresyonda bu değer %9.58 olarak bulunmuştur. YSA modelinin R<sup>2</sup> değeri, regresyon modelinkinden oldukça yüksektir. %10 hata payına göre model tahminlerinden doğru olanlarının yüzdesi, YSA'da %82 regresyonda %55'tir. Regresyona kıyasla, YSA modeli büyük şirketlerin İHA fiyatlarını tahmin etmede büyük ölçüde başarı sağlamıştır. Tüm bu ölçütlere göre, büyük şirketlerin ilk halka arzlarının fiyat performanslarını tahmin etmede YSA'nın oldukça iyi bir model konumundadır.

Ek 5'te bulunan performans grafikleri de yukarıdaki sonuçları desteklemektedir.

### 5.3.2 Koşullu Olasılıkların Hesaplanması

1995-2004 yılları arasında halka açılan büyük şirketlerin test verilerinden hesaplanan düşük fiyatlamaya ilişkin gerçek olasılıklar Tablo 29'da verilmiştir.

Tablo 29: Büyük şirketler için gerçek fiyatlama olasılıkları (B seti test verileri)

	Frekans	Olasılık
<b>Düşük Fiyatlama</b>	10	0.909091
<b>Aşırı Fiyatlama</b>	1	0.090909
<b>Toplam</b>	11	1.000000

Tablo 30: YSA modelinin tahmin performansları (B seti test verileri)

	Frekans	Olasılık
<b>Yanlış Tahmin</b>	2	0.181818
<b>Düşük Fiyatlama</b>	9	0.818182
<b>Aşırı Fiyatlama</b>	0	0.000000
<b>Toplam</b>	11	1.000000

Tablo 31: Regresyon modelinin tahmin performansları (B seti test verileri)

	Frekans	Olasılık
<b>Yanlış Tahmin</b>	5	0.454545
<b>Düşük Fiyatlama</b>	4	0.363636
<b>Aşırı Fiyatlama</b>	2	0.181818
<b>Toplam</b>	11	1.000000

A seti için uygulanan olasılık hesaplama prosedürleri B seti için de aynı şekilde uygulanmıştır. Tablo 30 ve 31’de her iki model için test verileri üzerinde yaptıkları tahminlerin doğru olma olasılıkları bulunmuştur. Buradaki olasılık bilgileri kullanılarak, *P(Tahmini düşük fiyatlamanın doğru olması / Gerçek düşük fiyatlama bilgisi)* koşullu olasılığı her iki model için hesaplanmıştır.

$$P(\text{YSA modelinin düşük fiyatlamaya ilişkin tahminin doğru olması} / \text{Gerçek düşük fiyatlama bilgisi}) = 0.818182 / 0.909091 = 0.900000$$

$$P(\text{Regresyon modelinin düşük fiyatlamaya ilişkin tahminin doğru olması} / \text{Gerçek düşük fiyatlama bilgisi}) = 0.363636 / 0.909091 = 0.400000$$

Hesaplanan koşullu olasılıklara göre, YSA modelinin regresyon modeline kıyasla oldukça yüksek bir performans ile doğru tahminler yapabilecek yetenekte olduğu görülmektedir.



## SONUÇ VE DEĞERLENDİRME

Türkiye’de sermaye piyasası konusundaki ilk ciddi adım 1982’lerde 2499 sayılı Sermaye Piyasası Kanunu’nun çıkarılması ile atılmıştır. 1990’larda halka açılan şirketlerin sayısının artması ile etkinlik kazanan bu piyasa, 2001 yılında yaşanan kriz etkisiyle düşüşe geçmiştir.

Türkiye’de her ne kadar İHA piyasasının etkinliği azalmış olsa da, şirketler halka açılarak genellikle hem finansman ihtiyacını giderebilmekte hem de risk paylaşımından büyük faydalar sağlayabilmektedirler.

Türkiye’de faaliyette bulunan şirketlerin karakteristik özelliği, aile şirketi kimliğine sahip olmalarıdır. Bu durum şirketin ömrünü, genelde kurucusu olan aile fertlerinin ya da yönetimde söz sahibi olan aile bireylerinin ömürleri ile sınırlayabilmektedir. Halka açılmak ve hisse senetlerinin menkul kıymet borsasında işlem görmesini sağlamak ile şirketler, sermaye piyasasının denetim mekanizmaları sayesinde kurumsallaşma süreçlerini hızlandırmakta ve modern yönetim tekniklerine daha kısa sürede kavuşabilmektedirler.

İlk halka arz edilen hisse senetlerinin fiyatlanması, zor ve karmaşık bir süreçtir. Bir İHA’nın gerçek piyasa fiyatı, ancak şirket halka açıldıktan ve hisse senetleri borsada işlem görmeye başladıktan sonra bilinebilmektedir. Genellikle İHA’ların fiyatının, borsada işlem gördükleri günün kapanışında yüksek değerlere ulaştığı görülmektedir. Bu durum hisse senetlerinin düşük fiyatlanması şeklinde adlandırılmaktadır. Bazı zamanlarda ise, İHA fiyatı ile ilk gün kapanış fiyatı arasında çok büyük farklar oluşabilmektedir. Bu aşırı farklar, İHA sürecinde rol oynayan yatırımcı, ihraç eden şirket ve aracı kurum taraflarından bazılarını memnun ederken bazılarını da bir takım fırsat kayıplarıyla baş başa bırakabilmektedir. Her İHA süreci bu durumu yaşamasa da, düşük fiyatlamayı maksimum düzeyde tespit edebilecek iyi bir tahmin aracına ihtiyaç duyulmaktadır.

Bu araştırmanın amacı, İHA hisse senetlerinin ilk gün kapanış fiyatlarını (piyasa değerlerini) belirlemede YSA'nın alternatif bir araç olduğunu göstermek ve Türkiye'deki İHA'lara ilişkin yazında, İHA'ların fiyatlanmasına dair az sayıda yapılan çalışmalara yeni bir tahminleme aracını tanıtarak katkıda bulunmaktır. İHA sürecinin karmaşık yapısından dolayı, genellikle erişilebilen veriler istatistiksel olarak düşük açıklama gücüne sahiptirler. Varsayımlar gerektiren parametrik yöntemlerin aksine, verilerin böyle bir yapıya sahip olması, YSA yönteminin doğru tahmin yapma etkinliğini azaltmamaktadır. YSA'lar değişkenler arasındaki gizli ilişkileri ortaya çıkarabildiklerinden eksik, düşük açıklama gücüne sahip veya doğrusal olmayan veriler karşısında bile iyi bir performans sergileyebilmektedirler.

Burada İHA'ların ilk günlük fiyat performansları, 1995 ile 2004 yılları arasında halka açılan şirketler büyüklüklerine göre iki ayrı grupta incelenmiştir. Büyüklük ölçütü olarak, şirketlerin halka açıldıkları zaman sahip oldukları varlıkların toplamı göz önünde bulundurulmuştur. 0 ile 50 milyon \$ arasında toplam varlığa sahip olan şirketler birinci grup (A seti) ve 50 milyon \$'den fazla toplam varlığa sahip olanlar ikinci grup (B seti) olarak ayrılmıştır. Her iki grup için ayrı YSA modelleri oluşturulmuş ve bu modellerinin fiyatlama performansı, gerçek fiyatlamalarla ve çoklu regresyon tekniğinin performansı ile kıyaslanmıştır.

Denemeler sonrasında, her iki veri seti için en iyi YSA modeli elde edilmiştir. Her iki YSA modeli ileri beslemeli bir ağ mimarisine sahip olup, öğrenme algoritması olarak hatayı geriye yayma algoritmasını kullanmaktadırlar. Bu iki YSA ağında normalizasyon fonksiyonu olarak logaritmik, geçiş fonksiyonu olarak da hiperbolik tanjant fonksiyonu kullanılmıştır. Her iki ağın öğrenme katsayısı 0.80, momentum katsayısı 0.50'dir. Bu iki ayrı veri grubu için elde edilen YSA modellerinin parametreleri hemen hemen aynı olmasına rağmen, iki ağın performansları birbirinden farklı bulunmuştur. Küçük şirketler için (A seti) elde edilen YSA modeli, çoklu regresyondan daha iyi sonuçlar vermesine rağmen, bu performans seviyesi iki YSA modelinin kıyaslanması durumunda çok çarpıcı görünmemektedir. Fakat büyük şirketler için elde edilen YSA modeli, çoklu regresyona kıyasla oldukça yüksek oranda hatasız tahminler yapabilmektedir. Her ne

kadar bu iki en iyi modelin parametreleri birbirinin aynı olsa da, farklı örnekler için farklı YSA'lar elde edilebileceği görülmüştür. İki modelin eğitim koşulları açısından farklılık yaratan iki neden bulunmaktadır. Burada hem farklı örneklerin etkisi hem de kullanılan yazılımın başlangıç değerlerini rasgele olarak ataması sonucu bu kadar farklı performans gösteren modellerle karşılaşmıştır. Bu durum örnek seçiminin YSA'lar için ne kadar kritik olduğunu göstermektedir.

Elde edilen modellerin doğruluk derecesi öncelikle gerçek ve tahmini değerlerin istatistiksel olarak karşılaştırılması ile ölçülmüştür. Her iki YSA modelinin gerçek fiyatlamalarla aynı dağılımı ürettiği görülmüştür. Bu sonuç, istatistiksel olarak "YSA modelinin ürettiği fiyatlar ile gerçek fiyatlar arasında fark yoktur" hipotezinin t-test ve Mann-Whitney testi kullanılarak test edilmesiyle doğrulanmıştır. Her iki testin sonucunda elde edilen p-değerleri %5'ten büyük oldukları için  $H_0$  hipotezi reddedilememiştir. Buna göre, geliştirilen YSA modellerinin ikisi de halka arzlarının ilk gün fiyat performanslarını tahmin edebilecek yeteneğe sahiptir.

Modellerin doğruluk derecesi, aynı zamanda  $R^2$ , ortalama mutlak hata ve koşullu olasılık değerlerine göre modellerin çoklu regresyon modeli ile kıyaslanması yoluyla değerlendirilmiştir.

Geliştirilen her iki YSA modelinin eğitim verileri kullanılarak her bir veri seti için ayrı regresyon modelleri elde edilmiştir.  $R^2$  ölçütüne göre, A setinden elde edilen YSA modeli 0.990, regresyon modeli ise 0.769 değerine sahiptir. B seti için ise, YSA 0.993, regresyon modeli ise 0.525 değerine sahiptir.

Ortalama mutlak hata kriterine göre, A seti için YSA 0.083, regresyon 0.107 değerine sahip iken, B setinde YSA 0.091, regresyon ise 0.096 değerlerine sahiptirler.

Her model için aynı zamanda düşük fiyatlamaya ilişkin yaptığı tahminlerin doğru olma olasılıkları hesaplanmıştır. A seti için, YSA'nın düşük fiyatlamayı doğru tahmin etme olasılığı 0.6154, regresyonun ise, 0.0769 olarak bulunmuştur. B setinde ise ilgili olasılıklar sırasıyla, 0.90 ve 0.40 olarak hesaplanmıştır. YSA ve regresyon için hesaplanan koşullu olasılıkların değerine göre, YSA modelinin regresyondan daha doğru tahminler yapabileceği açıkça görülmektedir.

Yukarıdaki üç performans ölçütüne göre değerlendirildiğinde, iki YSA modeli de çoklu regresyon analizinden daha iyi performans göstermektedir. Ekler bölümünde bulunan performans grafikleri de, bulunan sayısal sonuçları görsel olarak doğrulamaktadır. Örneğin, Şekil 24 ve 28'de regresyon modelinin hata varyasyonunun YSA'ninkinden daha büyük olduğu görülmektedir.

Bu araştırmanın bulgularının geliştirilebilir ve katkı yapılabilir olmasının yanında, YSA'nın şirketler tarafından alternatif bir karar destek aracı olarak kullanılabilmesi çalışmada elde edilen değerlerin ışığında rahatlıkla söylenebilir. Yukarıda bahsedilenlerin yanında, YSA'nın çoklu regresyona alternatif bir tahmin aracı olmasını sağlayacak başka nedenler de bulunmaktadır. Bunlardan biri, YSA'lar da hiç bir varsayım bulunmamasıdır. Çoklu regresyon modelinin kullanılması sırasında modelin altında yatan varsayımların sağlanması şarttır. Doğrusallık varsayımı, pek çok durumda sağlanmayabilmektedir. YSA, hem doğrusal hem de doğrusal olmayan sistemleri başarılı bir şekilde modelleyebilmektedir. Örneğin, bu çalışmada kullanılan girdi değişkenlerinin bir kısmı kukla değişken olarak modele girmektedir. Bu kukla değişkenler model yapısını doğrusallıktan uzaklaştırmaktadırlar. Bu değişkenlerin çoğu regresyon modelinde anlamsız çıkmıştır. Modelde bu değişkenlerin var olması, YSA'nın iyi tahminler yapma performansını etkilememiştir. Burada yapılan analizler sonucunda YSA modelleri çoklu regresyon analizine göre daha gerçek sonuçlar vermiştir.

Bir diğer neden ise, YSA'yı geliştirirken çok derin teorik bilgilere sahip olmak gerekmemektedir. Halbuki bir kullanıcının, çoklu regresyon analizi ve diğer

parametrik tahminleme yöntemlerini sağlıklı bir şekilde kullanabilmesi için teoriyi iyi anlaması ve varsayımları iyi analiz etmesi gerekir.

YSA modelleri kolay elde edilememektedir. YSA'nın bu avantajlarının yanında, bir model geliştirirken yaşattığı bazı zorluklar bulunmaktadır. Bunlar veri toplama, organize etme ve en iyisini bulma anlamında önemli ölçüde çaba gerektirmektedir. YSA doğrudan örnekler üzerinden öğrendiği için verilerin toplanması ve ağa gösterime hazırlanması deneme-yanılma yöntemleri ile gerçekleştirilmektedir. Hangi YSA'nın ne tür örneklerle iyi performans göstereceğine dair geliştirilmiş sistematik bilgiler bulunmadığından, her model ağı geliştiren kişinin tecrübesine göre kurulmaktadır. Doğru bilgiler doğru şekliyle ağa sunulmadığı zaman, YSA modelinin eğitim süresi çok fazla zaman alabilmektedir. Benzer şekilde, ağın eğitimi sırasında kullanılan tüm parametreler deneme-yanılma yöntemi ile belirlendiğinden uygun bir model buluncaya kadar tekrarlamalar nedeniyle çok uzun süre geçebilir.

Bu çalışmada, kullanılan yazılımın belirli fonksiyonlar ve parametrelerle sınırlı olması nedeniyle bazı kombinasyonlar denenmeden en iyi YSA modelleri seçilmiştir. Fakat bu, modelin etkinliği açısından bir dezavantaj yaratmamıştır. YSA bulunan çözümün en iyi olup olmadığı konusunda bilgi veremediğinden, başka kombinasyonlar denense de bulunan çözümün mevcut çözüme göre daha iyi olduğu konusunda kesin yargılar bulunamayabilecektir. Bu YSA'nın zayıf bir yönüdür.

Özetle, hem küçük şirketler hem de büyük şirketler için geliştirilen YSA modelleri, şirketlerin hisse senetlerinin piyasaya çıktıktan sonraki değerini yüksek bir doğruluk derecesi ile tahmin edebilmektedir. Bu modeller, İHA sürecinde ilk halka arz fiyatını belirlerken bir karar destek aracı olarak kullanılabilir.

## KAYNAKLAR

Aggarwal, R. & Klapper; L. (2003). Ownership Structure and Initial Public Offerings. *Policy Research Working Paper*, 3103. Erişim tarihi: 12.04.2004, <http://econ.worldbank.org>.

Atiya, A. F. (2001). Bankruptcy Prediction for Credit Risk Using Neural Networks: A Survey and New Result. *IEEE Transactions on Neural Networks*, 12-4 (929-935).

Bansal, A. & Kauffman, R. J. & Weitz, R. B. (1993). Comparing the Modeling Performance of Regression and Neural Networks as Data Quality Varies: A Business Value Approach. *Journal of Management Information Systems*; 10-1 (11-32).

Baron, D. P. (1982). A Model of the Demand for Investment Banking Advising and Distribution Services for New Issues. *Journal of Finance* 37 (955-976).

Baykasoğlu, A. & Özbakır, L. (2004). Yapay sinir Ağları ile Teslim Tarihi Belirleme. *YA/EM 2004 - Yöneylem Araştırması/Endüstri Mühendisliği 24. Ulusal Kongresi*.

Boritz, J. E. & Kennedy, D. B. (1995). Effectiveness of Neural Network Types for Prediction of Business Failure. *Expert Systems and Applications*, 9-4 (503-512.)

Bozer, A. & Göle, C. (1996). *Bankacılar için Kıymetli Evrak Hukuk Bilgisi*. Zirve Ofset, Ankara.

Brealey, A. R. & Myers, S.C. & Marcus, A.J. (1997). *İşletme Finansının Temelleri*. McGraw Hill-Literatür, İstanbul.

Brennan, M.J & Franks, J. (1997). Underpricing, Ownership and Control in Initial Public Offerings of Equity Securities in the UK. *Journal of Financial Economics*, 45 (391- 413).

Brockett, P.W. & Cooper, W. W. & Golden, L. & Pitaktong, U. (1994). A Neural Network Method for Obtaining an Early Warning of Insurer Insolvency. *The Journal of Risk and Insurance* 6 (402-424).

Chi, J. & Padgett, C. (2001). The Performance and Long-Run Characteristics of The Chinese IPO Market. Erişim tarihi: 12.05.2005,  
<http://www.fma.org/Chicago/Papers/longrunpaperconfe.pdf>

DeTienne, K. B. & Lewis, L.W. (2003). *Artificial Neural Networks for the Management Researcher: The State of the Art*. Brigham Young Üniversitesi, Brigham.

Dimovski, W. & Brooks, R. (2004). The Characteristics of Property Trust IPOs in Australia. *Australian Institute of Banking and Finance Conference*, Melbourne.

Drake, P. D. & Vetsuypens, M.R. (1993). IPO Underpricing and Insurance against Legal Liability, *Financial Management*, 22 (64-73).

Durukan, B. (2002). The Relationship Between IPO Returns and Factors Influencing IPO Performance: Case of Istanbul Stock Exchange. *Managerial Finance*, 28-2 (18-38).

Durukan, B. (2006). IPO Underpricing and Ownership Structure: Evidence from İstanbul Stock Exchange, *Initial Public Offerings: An International Perspective*, (Editör: Greg N. Gregoriou), Elsevier (Yayına kabul edilmiştir).

Düzakın, H. G. (1998). *İMKB'de Halka İlk Arzdan Sonra Hisse Sentlerinin Performanslarının Ölçümü ve Düşük Fiyatlandırma ile İlgili Yaklaşımların Firmalar ve Bunlara Aracılık Eden Kurumlar Açısından Değerlendirilmesi*. Yayınlanmamış Doktora Tezi. Çukurova Üniversitesi Sosyal Bilimler Enstitüsü, Adana.

Ergün, M. (1995). *Bilimsel Araştırmalarda Bilgisayarlı İstatistik Uygulamaları: SPSS for Windows*. Ocak Yayınları, Ankara.

Field, L.C. & Sheehan, D. P. (2004). IPO Underpricing and Outside Blockholdings. *Journal of Corporate Finance*, 10 (263–280).

Freeman, A. J. & Skapura, D. M. (1991). *Neural Networks – Algorithms, Applications and Programming Techniques*. Addison – Wesley Publishing Company, Amerika Birleşik Devletleri.

Griffin, J.M. & Harris, J.H. & Topaloğlu, S. (2004). Why are IPO Investors Net Buyers through Lead Underwriters? *Corporate Finance*.

Habib, M. A. & Ljungqvist, A. P. (1998). Underpricing and IPO Proceeds: A Note. *Economics Letters*, 61 (381–383).

Halka Arz Prosedürü. Erişim tarihi: 20.05.2005, [www.imkb.gov.tr/yayinlar/halkaarz](http://www.imkb.gov.tr/yayinlar/halkaarz)

Hamzaçebi, C. & Kutay, F. (2004). Yapay Sinir Ağları ile Türkiye Elektrik Enerjisi Tüketiminin 2010 Yılına Kadar Tahmini. *Gazi Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi*, 19–3 (227–233).

Haykin, S. (1994). *Neural Networks: A Comprehensive Foundation*, Macmillian College Publishing Company, New York.

Hill, T. & O'Connor, M. & Remus, W. (1996). Neural Networks Models for Time Series Forecasts. *Management Sciences*, 42–7 (1082–1092).

Hsieh, C. (1993). Some Potential Applications of Artificial Neural Systems In Financial Management, *Journal of Systems Management ABI/INFORM Global*, 44–4 (12).

Hutchinson, J. M. & Lo, A. & Poggio, T. (1994). A Nonparametric Approach to Pricing and Hedging Derivative Securities Via Learning Networks. *Massachusetts*



*Institute of Technology Artificial Intelligence Laboratory and Center for Biological and Computational Learning, 1471-92.*

Indro, D. C. & Jiang, C.X. & Patuwo, B.E. & Zhang, G.P. (1998). Predicting Mutual Fund Performance Using Artificial Neural Networks. *Omega, International Journal of Management Science*, 27 (373–380).

Jain, B. A. & Nag, N. N. (1995). Artificial Neural Network Models for Pricing Initial Public Offerings. *Decision Sciences*, 26–3 (283–302).

Jain, A.K. & Mao, J. (1996). Artificial Neural Networks:A Tutorial. *IEEE 0018-9162*, (31–43).

Kaastra, I. & Boyd, M. (1996). Designing a Neural Network for Forecasting Financial and Economic Time Series. *Neurocomputing*, 10 (215- 236).

Kalyanpur, A. & Simon, M. (2001). Pacman using Genetic Algorithms and Neural Networks. *Project Report for ENEE 459N*.

Kaplan, C. A. (2001). Collective Intelligence: A New Approach to Stock Price Forecasting. *Proceedings of the 2001 IEEE Systems, Man, and Cybernetics Conference*.

Keller, G. & Warrack, B.(2003). *Statistics for Management and Economics*. Thomson Learning, Brooks/Cole. 6. Baskı, Amerika Birleşik Devletleri.

Kıymaz, Halil (1996), Halka İlk Arzedilen Hisse Senetlerinin Performansları: İMKB İmalat Sektörü Uygulaması, Sermaye Piyasası ve İMKB Üzerine Çalışmalar, *İşletme ve Finans Yayınları*, 4, Ankara.

Kıymaz, H. (2000). The Initial and Aftermarket Performances of IPOs in an Emerging Market: Evidence from Istanbul Stock Exchange. *Journal of Multinational Financial Management* 10 (213-227).

Kıymetli Evrak Yasası (Securities Act of 1933). Erişim Tarihi: 10.06.2005, (<http://www.sec.gov/divisions/corpfin/33act>)

Kiang, M. A. (2003). Comparative Assessment of Classification Methods. *Decision Support Systems*, 35 (441–454).

Kim, M. & Ritter, J. R. (1999). Valuing IPOs. *Journal of Financial Economics*, 53 (409–437).

Klein, B. D. & Rossin, D. F. (1999). Data Quality in Neural Network Models: Effect of Error Rate and Magnitude of Error on Predictive Accuracy. *OMEGA*, 27 (569–582).

Kooli, M. & Suret, J. M. (2002). The Underpricing of Initial Public Offerings: Further Canadian Evidence. *CIRANO Working Papers - 50*. Erişim tarihi: 12.04.2005, <http://papers.ssrn.com/sol3/papers>.

Krycha, K. A. & Wagner, U. (1999). Applications of Artificial Neural Networks in Management Science: A Survey. *Journal of Retailing and Consumer Services*, 6 (185–203).

Kröse, B. & Smagt, P. V. (1996). *An Introduction to Neural Networks*. Amsterdam Üniversitesi, Amsterdam.

Lawrence, S. & Giles, C. L. & Tsoi, A.C. (1996). What Size Neural Network Gives Optimal Generalization? Convergence Properties of Backpropagation. *Technical Report UMIACS-TR-96-22 / CS-TR-3617, Institute for Advanced Computer Studies*. Maryland Üniversitesi.

- Levine, D.M.& Berenson, M.L.& Stephan, D. (1997). *Statistics for Managers Using Microsoft Excel*. Prentice Hall, New Jersey.
- Levis, M. (1993). The Long Run Performance of Initial Public Offerings: The UK Experience 1980-88. *Financial Management*, 22-1 (28-41).
- Ljungqvist, A. & Wilhelm, W. J. (2003). IPO Pricing in the Dot-com Bubble. *The Journal of Finance*, LVII-2 (723-752).
- Ljungqvist, A. (2005). *IPO Underpricing*. Handbook in Corporate Finance: Empirical Corporate Finance, 12. Bölüm.
- Loughran, T.& Ritter, J.R. & Rydqvist, K. (1994). Initial Public Offerings: International Insights. *Pacific-Basin Finance Journal*, 2 (165-199).
- Loughran, T. & Ritter, J.R. (2002). Why Don't Issuers Get Upset About Leaving Money on the Table in IPOs. *The Review of Financial Studies*, Özel Sayısı, 15-2 (413-443)
- Lübis, H.Y. (2001). *Initial Public Offering Prediction Using Neural Network*. Yayınlanmamış Doktora Tezi, Mühendislik ve Uygulamalı Bilimler Fakültesi, George Washington Üniversitesi, Amerika Birleşik Devletleri.
- McCarthy, E. (1999). Pricing IPOs: Science or Science Fiction? *Journal of Accountancy*, Eylül 1999 (51-58).
- Muscarella, C. J. & Vetsuypens, M. R. (1989). A Simple Test of Baron's Model of IPO Underpricing, *Journal of Financial Economics* 24 (125-135).
- Öztemel, E. (2003). *Yapay Sinir Ağları*. Papatya Yayıncılık, İstanbul.

Pagano, M. & Panetta, F. & Zingales, L. (1998). Why Do Companies Go Public? An Empirical Analysis. *The Journal of Finance*, LIII-1 (27-64).

Ritter, J. R.(1998). Initial Public Offerings. *Contemporary Finance Digest*, 2-1(5-30)

Ritter, J. R. & Welch, I. (2002). A Review of IPO Activity, Pricing and Allocations. *The Journal of Finance*, LVII-4 (1795-1828).

Rock, K. (1986). Why New Issues Are Underpriced. *Journal of Financial Economics* 15 (187-212).

Sermaye Piyasası ve Borsa Temel Bilgiler Klavuzu (1997). İMKB Araştırma Yayın ve Eğitim Müdürlüğü, Eğitim Yayınları No:1, İstanbul.

Shachmurove, Y. & Witkowska, D. ( 2000). *Utilizing Artificial Neural Network Model to Predict Stock Markets*. Center for Analytic Research in Economics and the Social Sciences (CARESS), Working Paper #00-11. University of Pensilvanya, Amerika Birleşik Devletleri.

Shachmurove, Y. (2002). *Applying Artificial Neural Networks to Business, Economics and Finance*. Erişim tarihi: 14.11.2004, <http://qudata.com/lib/neuronet/>

Sharda, R. & Patil, R.B. (1992). Connectionist Approach to Time Series Prediction: An Emprical Test. *Journal of Intelligent Manufacturing*, 3 (317-323).

Shiwakoti,R. K.& Hudson, R.& Short, H. (2004). A Study of the Initial Returns and the Aftermarket Performance of Initial Public Offerings of Demutualised Building Societies in the United Kingdom, Canterbury Business School, Working Papers Series, 60.

Simon, H. A. (1983). *Why Should Machines Learn? In: Machine Learning – An Artificial Intelligence Approach*. Tioga Publishing Company, California:

Smart, S.B. & Zutter, C. J. (2003). Control as a Motivation for Underpricing: A Comparison of Dual and Single-Class IPOs. *Journal of Financial Economics*, 69 (85-110)

Sorularla Borsa ve Sermaye Piyasası (2003). İMKB Yayınları, İstanbul.

SPK Tebliği Seri:5 No:19. *Aracılık Faaliyetleri ve Aracı Kuruluşlara İlişkin Esaslar Tebliği*. Banka ve Sermaye Piyasası Mevzuatı, Lebib Yalkın Yayınları.

Rao, V. B. (1995). *C++ Neural Networks and Fuzzy Logic*. IDG Books Worldwide, ISBN: 1.558.515.526, Amerika Birleşik Devletleri.

Reeves, C. R. (1995). *Modern Heuristic Techniques for Combinatorial Problems*. McGraw Hill, Londra.

Tang, Z. & Almeida, C.& Fishwick, P.A. (1991). Time Series Forecasting Using Neural Networks vs Box-Jenkins Methodology. *Simulation*, 57-5 (303-310).

Tan, C. N.W. (1997). *An Artificial Neural Networks Primer with Financial Applications Examples in Financial Distress Predictions and Foreign Exchange Hybrid Trading System*. School of Information Technology, Bond University, QLD 4229, Avustralya

Tenti, P. (1996). Forecasting Foreign Exchange Rates Using Recurrent Neural Networks. *Applied Artificial Intelligence*, 10 (567-581)

Tınıç, S.M., 1988, Anatomy of Initial Public Offerings of Common Stock, *Journal of Finance*, 43 (789-822).

Trippi, R. R. & Turban, E. (1996). *Neural Network in Finance and Investing*, Irwin Professional Publishing, Chicago.

Tukey, J.W. (1960). A Survey of Sampling from Contaminated Normal Distributions. *Contributions to Probability and Statistics*. Stanford University Press, Stanford, California.

Vemuri V. R. (1994). *Artificial Neural Networks: Concepts and Control Applications*, IEEE Computer Society Pres, Los Alamitos, California.

Wong, B. K. & Selvi, Y. (1998). Neural Network Applications in Finance: A Review and Analysis of Literature (1990–1996). *Information and Management* 34 (129-139)

Yıldız, B. (1999). *Finansal Başarısızlığın Öngörülmesinde Yapay Sinir Ağı kullanımı ve Ampirik Bir Çalışma*. Yayınlanmamış Doktora Tezi. Dumlupınar Üniversitesi Sosyal Bilimler Enstitüsü, Kütahya.

Yükçü, S. vd. (1999). *Finansal Yönetim*. Vizyon Yayınları, İzmir.

Zhang, G. & Patuwo, B.E. & Hu, M.Y. (1998) "Forecasting with Artificial Neural Networks: The State of the Art", *International Journal of Forecasting*, 14 (35- 62).

## BİBLİYOGRAFI

Andereescu, A. (2004). Forecasting Corporate Earnings: A Data Mining Approach. Yüksek Lisans Tezi. İsveç Ekonomi ve İşletme Okulu, İsveç.

Chatterjee, A. vd. (2000). Artificial Neural Network and the Financial Markets: A Survey. *Managerial Finance*, Cilt 26 No.12 (32-44).

Demuth, H. & Beale, M. (2000). *Neural Network Toolbox*. The MathWorks Inc., Amerika Birleşik Devletleri.

Efe, Ö. & Kaynak, O. (2000). *Yapay Sinir Ağları ve Uygulamaları*. Boğaziçi Üniversitesi, İstanbul.

Haykin, S. (2001). *Kalman Filtering and Neural Networks*. John Wiley and Sons, Kanada.

Hill, T., O'Connor and M., R., W. Neural Network Models for Time Series Forecasts. *Management Science* 1996; 42(7): 1082-1092.

Kalyvas, E. (2001). *Using Neural Networks and Genetic Algorithms to Predict Stock Market Returns*. Yüksek Lisans Tezi. Manchester Üniversitesi Fen ve Mühendislik Fakültesi, Manchester.

Stich, T. J. vd. (2000). The Applications of Artificial Neural Networks to Monitoring and Control of an Induction Hardening Process. *Journal of Industrial Technology*, Cilt 16, No.1, (2-11).

Tan, C. N. W. & Dihadjo, H. (2001). A Study on Using Artificial Neural Networks to Develop an Early Warning Predictor for Credit Union Financial Distress with Comparison to the Probit Model. *Managerial Finance*, Cilt 27 No.4 (56-77)

Thurston, J. (2002). GIS & Artificial Neural Network: Does Your GIS Think?,  
Eriřim: 15.01.2005, [www.GISCafe.com](http://www.GISCafe.com)

Yao, X. (1999). Evolving Artificial Neural Networks. *Proceedings of IEEE*, Cilt 87,  
No. 9 (1423–1447).







## **EKLER**

Ek 1: Geliştirilen en iyi YSA modelinin bağlantı ağırlıkları (A seti)

	nöron 1	nöron 2	nöron 3	nöron 4	nöron 5	nöron 6	nöron 7	nöron 8	nöron 9
eşik değeri	0,0063	0,2841	0,7735	0,4536	-0,1407	0,5594	0,5729	0,3003	-0,4146
girdi 1	-0,1345	0,2731	0,1425	0,1624	-0,2336	-0,1256	-0,1520	0,0752	0,2237
girdi 2	-0,0388	-0,0923	-0,3615	-0,1242	-0,3787	-0,0797	-0,2446	-0,8604	-0,0439
girdi 3	0,0630	0,3375	-0,2632	-0,1535	0,2600	-0,0364	-0,0777	0,3441	-0,0781
girdi 4	0,9557	0,3975	-0,2138	-0,5072	-0,1650	-0,2606	-0,2945	-0,0375	-0,1213
girdi 5	-0,7313	0,0981	0,2295	0,2934	-0,4006	0,1370	0,3893	0,0723	0,1667
girdi 6	-0,1810	-0,1579	-0,3101	-0,3092	0,6168	0,2236	0,1302	0,6456	0,0718
girdi 7	-0,1636	-0,0180	0,1992	0,2840	-0,4251	-0,1629	0,2873	-0,4852	-0,0393
girdi 8	0,1489	0,1837	0,5103	0,7805	-0,0036	0,2604	0,4864	0,3535	0,1725
girdi 9	-0,4117	0,2421	-0,1620	-0,1058	0,3522	0,0421	-0,2969	0,5160	0,3442
girdi 10	-0,0968	0,9113	0,2034	0,5003	-0,2723	0,1175	0,2077	-0,0640	0,2403
girdi 11	-0,0757	-0,4789	-0,3323	-0,0522	0,9694	0,1694	0,1297	0,3295	-0,1073
girdi 12	-0,1410	0,2298	-0,1360	0,4826	0,2169	0,0623	0,2293	0,0781	1,0116
girdi 13	-0,0241	-0,3130	-0,4380	-0,0399	0,0131	-0,6742	-0,4275	-0,7341	-0,3970
girdi 14	-0,1813	0,4287	-0,1566	-0,3699	0,3914	-0,7060	-0,2602	-0,0609	0,4730

	nöron 10	nöron 11	nöron 12	nöron 13	nöron 14	nöron 15	nöron 16	nöron 17	nöron 18
eşik değeri	-0,4508	-0,7846	-0,0362	0,0047	0,0274	-0,5130	0,0031	0,0063	0,2841
girdi 1	0,1324	0,0065	-0,2568	0,2885	-0,1559	0,0210	0,0337	-0,1345	0,2731
girdi 2	-0,0376	0,3015	-0,4030	0,4302	-0,4613	0,7628	0,1752	-0,0388	-0,0923
girdi 3	-0,1717	-0,0103	0,0420	-0,3627	0,2667	-0,2664	-0,2820	0,0630	0,3375
girdi 4	0,2381	0,1767	-0,3411	-0,3445	-0,0898	0,3838	0,5742	0,9557	0,3975
girdi 5	-0,4953	-0,4542	0,6525	0,3949	0,1464	-0,2239	-0,5765	-0,7313	0,0981
girdi 6	-0,1964	-0,1343	0,6453	-0,6137	0,5218	-0,1813	-0,2571	-0,1810	-0,1579
girdi 7	0,3944	-0,0839	-0,3740	0,2203	-0,6680	-0,0007	0,5042	-0,1636	-0,0180
girdi 8	-0,3344	-0,2301	-0,2688	0,1593	0,2620	-0,2639	0,0982	0,1489	0,1837
girdi 9	-0,1094	-0,0044	0,2855	-0,3634	0,1627	-0,1573	-0,5310	-0,4117	0,2421
girdi 10	-0,1798	-0,1829	0,2440	-0,3922	0,1034	-0,3946	-0,0960	-0,0968	0,9113
girdi 11	-0,0530	0,1047	-0,1312	-0,1326	0,3333	-0,2652	-0,0648	-0,0757	-0,4789
girdi 12	0,2195	-0,2841	-0,2342	-0,8298	-0,3562	-0,2650	0,0290	-0,1410	0,2298
girdi 13	0,6941	0,6327	-0,5530	0,2192	-0,6033	0,3501	0,3787	-0,0241	-0,3130
girdi 14	0,1615	0,4476	-0,2795	-0,2706	0,1472	0,1021	0,3300	-0,1813	0,4287

Ek 1 (devamı)

	nöron 19	nöron 20	nöron 21	nöron 22	nöron 23	nöron 24	nöron 25	nöron 26	nöron 27
eşik değeri	0,7735	0,4536	-0,1407	0,5594	0,5729	0,3003	-0,4146	-0,4508	-0,7846
girdi 1	0,1425	0,1624	-0,2336	-0,1256	-0,1520	0,0752	0,2237	0,1324	0,0065
girdi 2	-0,3615	-0,1242	-0,3787	-0,0797	-0,2446	-0,8604	-0,0439	-0,0376	0,3015
girdi 3	-0,2632	-0,1535	0,2600	-0,0364	-0,0777	0,3441	-0,0781	-0,1717	-0,0103
girdi 4	-0,2138	-0,5072	-0,1650	-0,2606	-0,2945	-0,0375	-0,1213	0,2381	0,1767
girdi 5	0,2295	0,2934	-0,4006	0,1370	0,3893	0,0723	0,1667	-0,4953	-0,4542
girdi 6	-0,3101	-0,3092	0,6168	0,2236	0,1302	0,6456	0,0718	-0,1964	-0,1343
girdi 7	0,1992	0,2840	-0,4251	-0,1629	0,2873	-0,4852	-0,0393	0,3944	-0,0839
girdi 8	0,5103	0,7805	-0,0036	0,2604	0,4864	0,3535	0,1725	-0,3344	-0,2301
girdi 9	-0,1620	-0,1058	0,3522	0,0421	-0,2969	0,5160	0,3442	-0,1094	-0,0044
girdi 10	0,2034	0,5003	-0,2723	0,1175	0,2077	-0,0640	0,2403	-0,1798	-0,1829
girdi 11	-0,3323	-0,0522	0,9694	0,1694	0,1297	0,3295	-0,1073	-0,0530	0,1047
girdi 12	-0,1360	0,4826	0,2169	0,0623	0,2293	0,0781	1,0116	0,2195	-0,2841
girdi 13	-0,4380	-0,0399	0,0131	-0,6742	-0,4275	-0,7341	-0,3970	0,6941	0,6327
girdi 14	-0,1566	-0,3699	0,3914	-0,7060	-0,2602	-0,0609	0,4730	0,1615	0,4476


	nöron 28	nöron 29	nöron 30	nöron 31	nöron 32	nöron 33	nöron 34	nöron 35
eşik değeri	-0,0362	0,0047	0,0274	-0,5130	0,0031	0,0063	0,2841	0,7735
girdi 1	-0,2568	0,2885	-0,1559	0,0210	0,0337	-0,1345	0,2731	0,1425
girdi 2	-0,4030	0,4302	-0,4613	0,7628	0,1752	-0,0388	-0,0923	-0,3615
girdi 3	0,0420	-0,3627	0,2667	-0,2664	-0,2820	0,0630	0,3375	-0,2632
girdi 4	-0,3411	-0,3445	-0,0898	0,3838	0,5742	0,9557	0,3975	-0,2138
girdi 5	0,6525	0,3949	0,1464	-0,2239	-0,5765	-0,7313	0,0981	0,2295
girdi 6	0,6453	-0,6137	0,5218	-0,1813	-0,2571	-0,1810	-0,1579	-0,3101
girdi 7	-0,3740	0,2203	-0,6680	-0,0007	0,5042	-0,1636	-0,0180	0,1992
girdi 8	-0,2688	0,1593	0,2620	-0,2639	0,0982	0,1489	0,1837	0,5103
girdi 9	0,2855	-0,3634	0,1627	-0,1573	-0,5310	-0,4117	0,2421	-0,1620
girdi 10	0,2440	-0,3922	0,1034	-0,3946	-0,0960	-0,0968	0,9113	0,2034
girdi 11	-0,1312	-0,1326	0,3333	-0,2652	-0,0648	-0,0757	-0,4789	-0,3323
girdi 12	-0,2342	-0,8298	-0,3562	-0,2650	0,0290	-0,1410	0,2298	-0,1360
girdi 13	-0,5530	0,2192	-0,6033	0,3501	0,3787	-0,0241	-0,3130	-0,4380
girdi 14	-0,2795	-0,2706	0,1472	0,1021	0,3300	-0,1813	0,4287	-0,1566

Ek 1 (devamı)


	çıktı birimi		çıktı birimi		çıktı birimi
nöron 1	0,0684	nöron 14	0,0546	nöron 27	-0,0164
nöron 2	0,0133	nöron 15	0,0264	nöron 28	0,0497
nöron 3	0,0368	nöron 16	-0,0162	nöron 29	0,0528
nöron 4	0,1472	nöron 17	0,0684	nöron 30	0,0546
nöron 5	-0,0287	nöron 18	0,0133	nöron 31	0,0264
nöron 6	-0,0055	nöron 19	0,0368	nöron 32	-0,0162
nöron 7	0,0489	nöron 20	0,1472	nöron 33	0,0684
nöron 8	-0,0732	nöron 21	-0,0287	nöron 34	0,0133
nöron 9	-0,0417	nöron 22	-0,0055	nöron 35	-0,1152
nöron 10	0,0353	nöron 23	0,0489	eşik değeri	-0,0162
nöron 11	-0,0164	nöron 24	-0,0732		
nöron 12	0,0497	nöron 25	-0,0417		
nöron 13	0,0528	nöron 26	0,0353		

**Ek 2: Geliştirilen en iyi YSA modelinin performans grafikleri (A seti)**






Şekil 23: YSA ve regresyon modellerinden elde edilen tahminlerin gerçek değerlerle karşılaştırılması (A seti eğitim verileri)




Şekil 24: YSA ve regresyon modellerinin mutlak hata değerlerine göre karşılaştırılması (A seti eğitim verileri)



Şekil 25: YSA ve regresyon modellerinden elde edilen tahminlerin gerçek değerlerle karşılaştırılması (A seti test verileri)





Şekil 26: YSA ve regresyon modellerinin mutlak hata değerlerine göre karşılaştırılması (A seti test verileri)

Ek 3: B seti için geliştirilen en iyi YSA modelinin bağlantı ağırlıkları

	nöron 1	nöron 2	nöron 3	nöron 4	nöron 5	nöron 6	nöron 7	nöron 8	nöron 9
eşik değeri	-0,1758	-0,3591	0,1195	0,0593	0,4518	0,0247	0,6774	0,7024	0,2604
girdi 1	-0,1619	0,2594	0,0772	-0,0213	-0,0988	-0,1983	0,3538	0,0573	0,0852
girdi 2	0,0355	-0,1604	0,1281	-0,3084	0,3278	0,2276	-0,3436	0,1090	-0,5151
girdi 3	0,4060	0,0558	-0,0045	0,0767	-0,3398	-0,1854	0,0646	-0,3401	0,0248
girdi 4	0,4471	-0,1658	0,2803	0,3203	0,2891	0,0128	0,4045	0,4024	0,3287
girdi 5	-0,7350	0,0538	0,0212	-0,1716	0,2827	0,0865	0,3993	0,1819	-0,3635
girdi 6	0,4015	0,0560	-0,1412	0,3836	-0,3147	-0,1766	-0,0708	0,0795	0,3414
girdi 7	-0,4224	-0,3775	0,3046	0,6497	0,1883	0,4194	-0,0565	0,0826	-0,2050
girdi 8	0,2989	0,3643	0,1950	-0,3140	-0,2093	-0,2397	-0,4900	-0,0650	0,0149
girdi 9	0,0177	-0,0267	-0,1757	-0,3760	0,5239	0,0754	0,1562	0,2110	0,4744
girdi 10	-0,2161	0,0264	0,4446	-0,2189	0,3554	-0,2738	0,6874	0,4102	-0,1195
girdi 11	0,1377	0,4392	-0,7605	-0,0599	-0,0489	0,3508	-0,3931	-0,3443	-0,2053
girdi 12	0,3292	-0,0138	0,5793	0,3181	-0,1841	0,5711	0,3156	0,0227	-0,4525
girdi 13	-0,1252	-0,1304	-0,1583	-0,9576	0,3068	0,2456	-0,1485	-0,1612	-0,6766
girdi 14	0,0534	0,6731	-0,0147	-0,3001	-0,2863	-0,6332	0,2073	-0,3733	0,3567

	nöron 10	nöron 11	nöron 12	nöron 13	nöron 14	nöron 15	nöron 16	nöron 17	nöron 18
eşik değeri	0,2799	-0,5539	0,2834	-0,6578	-0,4556	-0,4199	0,0009	-0,1758	-0,3591
girdi 1	0,0309	-0,0177	-0,2912	0,2377	-0,0945	-0,0381	0,0274	-0,1619	0,2594
girdi 2	0,0162	-0,0919	0,4058	-0,0260	-0,2723	0,2364	0,0558	0,0355	-0,1604
girdi 3	0,2100	0,3049	-0,2760	0,1248	-0,2536	-0,0857	0,0901	0,4060	0,0558
girdi 4	1,1135	-0,2798	-0,3171	-0,4333	-0,7176	-0,1028	-0,3772	0,4471	-0,1658
girdi 5	-0,5377	0,1179	0,3057	-0,0427	0,0269	0,0585	0,9870	-0,7350	0,0538
girdi 6	-0,2891	0,0281	-0,4241	0,1836	0,0837	-0,0913	-0,0774	0,4015	0,0560
girdi 7	0,4638	-0,5353	0,5588	0,0895	-0,1948	0,1780	-0,1100	-0,4224	-0,3775
girdi 8	0,0225	-0,0314	0,0083	0,2074	0,6207	0,4194	-0,1430	0,2989	0,3643
girdi 9	-0,1147	-0,0151	-0,1964	-0,4432	-0,0348	0,2569	0,2877	0,0177	-0,0267
girdi 10	0,0271	-0,3760	0,1091	-0,3676	0,1638	-0,2837	0,4410	-0,2161	0,0264
girdi 11	-0,0934	0,5490	-0,0099	0,1533	0,1054	0,3821	-0,1216	0,1377	0,4392
girdi 12	0,2321	0,1372	-0,3131	-0,0658	-0,6954	-0,1242	0,1611	0,3292	-0,0138
girdi 13	0,0330	0,1860	0,3775	-0,0378	-0,0847	0,8213	0,1648	-0,1252	-0,1304
girdi 14	0,0821	0,8400	-0,6887	0,2344	-0,3716	-0,3435	0,6564	0,0534	0,6731

Ek 3: (Devamı)

	nöron 19	nöron 20	nöron 21	nöron 22	nöron 23	nöron 24	nöron 25	nöron 26	nöron 27
eşik değeri	0,1195	0,0593	0,4518	0,0247	0,6774	0,7024	0,2604	0,2799	-0,5539
girdi 1	0,0772	-0,0213	-0,0988	-0,1983	0,3538	0,0573	0,0852	0,0309	-0,0177
girdi 2	0,1281	-0,3084	0,3278	0,2276	-0,3436	0,1090	-0,5151	0,0162	-0,0919
girdi 3	-0,0045	0,0767	-0,3398	-0,1854	0,0646	-0,3401	0,0248	0,2100	0,3049
girdi 4	0,2803	0,3203	0,2891	0,0128	0,4045	0,4024	0,3287	1,1135	-0,2798
girdi 5	0,0212	-0,1716	0,2827	0,0865	0,3993	0,1819	-0,3635	-0,5377	0,1179
girdi 6	-0,1412	0,3836	-0,3147	-0,1766	-0,0708	0,0795	0,3414	-0,2891	0,0281
girdi 7	0,3046	0,6497	0,1883	0,4194	-0,0565	0,0826	-0,2050	0,4638	-0,5353
girdi 8	0,1950	-0,3140	-0,2093	-0,2397	-0,4900	-0,0650	0,0149	0,0225	-0,0314
girdi 9	-0,1757	-0,3760	0,5239	0,0754	0,1562	0,2110	0,4744	-0,1147	-0,0151
girdi 10	0,4446	-0,2189	0,3554	-0,2738	0,6874	0,4102	-0,1195	0,0271	-0,3760
girdi 11	-0,7605	-0,0599	-0,0489	0,3508	-0,3931	-0,3443	-0,2053	-0,0934	0,5490
girdi 12	0,5793	0,3181	-0,1841	0,5711	0,3156	0,0227	-0,4525	0,2321	0,1372
girdi 13	-0,1583	-0,9576	0,3068	0,2456	-0,1485	-0,1612	-0,6766	0,0330	0,1860
girdi 14	-0,0147	-0,3001	-0,2863	-0,6332	0,2073	-0,3733	0,3567	0,0821	0,8400

	nöron 28	nöron 29	nöron 30	nöron 31	nöron 32	nöron 33	nöron 34	nöron 35
eşik değeri	0,2834	-0,6578	-0,4556	-0,4199	0,0009	-0,1758	-0,3591	0,1195
girdi 1	-0,2912	0,2377	-0,0945	-0,0381	0,0274	-0,1619	0,2594	0,0772
girdi 2	0,4058	-0,0260	-0,2723	0,2364	0,0558	0,0355	-0,1604	0,1281
girdi 3	-0,2760	0,1248	-0,2536	-0,0857	0,0901	0,4060	0,0558	-0,0045
girdi 4	-0,3171	-0,4333	-0,7176	-0,1028	-0,3772	0,4471	-0,1658	0,2803
girdi 5	0,3057	-0,0427	0,0269	0,0585	0,9870	-0,7350	0,0538	0,0212
girdi 6	-0,4241	0,1836	0,0837	-0,0913	-0,0774	0,4015	0,0560	-0,1412
girdi 7	0,5588	0,0895	-0,1948	0,1780	-0,1100	-0,4224	-0,3775	0,3046
girdi 8	0,0083	0,2074	0,6207	0,4194	-0,1430	0,2989	0,3643	0,1950
girdi 9	-0,1964	-0,4432	-0,0348	0,2569	0,2877	0,0177	-0,0267	-0,1757
girdi 10	0,1091	-0,3676	0,1638	-0,2837	0,4410	-0,2161	0,0264	0,4446
girdi 11	-0,0099	0,1533	0,1054	0,3821	-0,1216	0,1377	0,4392	-0,7605
girdi 12	-0,3131	-0,0658	-0,6954	-0,1242	0,1611	0,3292	-0,0138	0,5793
girdi 13	0,3775	-0,0378	-0,0847	0,8213	0,1648	-0,1252	-0,1304	-0,1583
girdi 14	-0,6887	0,2344	-0,3716	-0,3435	0,6564	0,0534	0,6731	-0,0147

Ek 3 (Devamı)

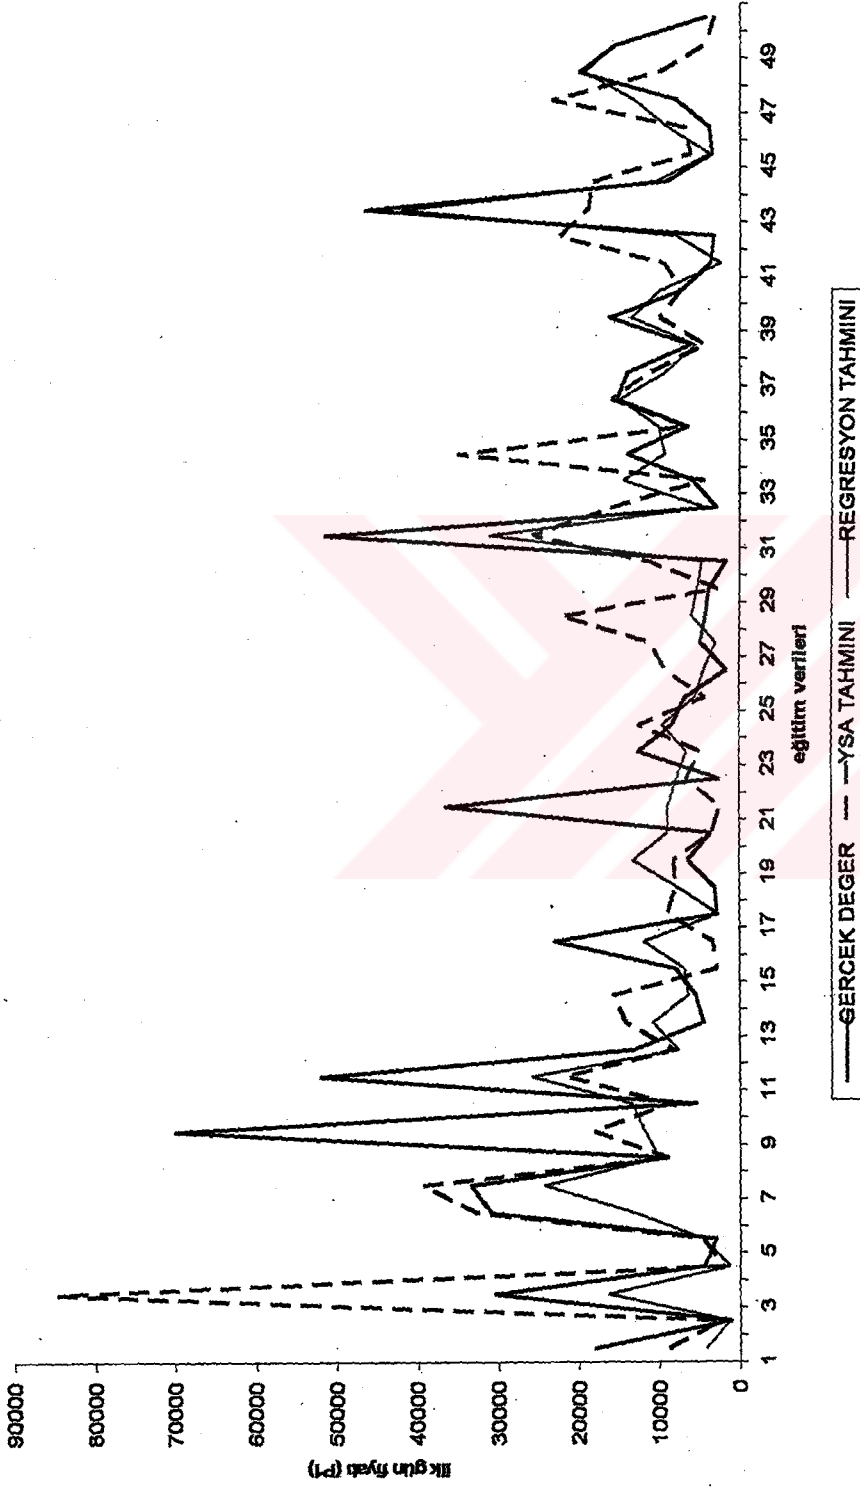
	çıkıtı birimi		çıkıtı birimi		çıkıtı birimi
nöron 1	0,0394	nöron 14	0,0462	nöron 27	-0,0566
nöron 2	-0,0920	nöron 15	0,0586	nöron 28	-0,0423
nöron 3	-0,0767	nöron 16	0,0508	nöron 29	0,0499
nöron 4	-0,0159	nöron 17	0,0394	nöron 30	0,0462
nöron 5	-0,0927	nöron 18	-0,0920	nöron 31	0,0586
nöron 6	0,1046	nöron 19	-0,0767	nöron 32	0,0508
nöron 7	0,0183	nöron 20	-0,0159	nöron 33	0,0394
nöron 8	0,0533	nöron 21	-0,0927	nöron 34	-0,0920
nöron 9	0,0361	nöron 22	0,1046	nöron 35	0,3078
nöron 10	0,1072	nöron 23	0,0183	eşik değeri	0,0508
nöron 11	-0,0566	nöron 24	0,0533		
nöron 12	-0,0423	nöron 25	0,0361		
nöron 13	0,0499	nöron 26	0,1072		

Ek 4: B seti için geliştirilen alternatif YSA modelleri


Ara katmandaki nöron sayısı	Öğrenme katsayısı	Ortalama mutlak hata	R <sup>2</sup>	Ortalama	Std. Sapma	Medyan
1	0,2	0,049023	99,53%	8,9910321	0,799165273	8,49561788
1	0,4	0,055056	97,68%	9,14313162	0,669028439	8,7270475
4	0,6	0,016456	99,93%	9,01127856	0,939768171	8,8306472
5	0,8	0,018475	99,91%	8,96916981	0,948087264	8,83655359
6	0,7	0,024728	99,91%	9,15468921	0,873804775	9,09341871
11	0,6	1,06E-16	100,00%	9,00090179	0,987251737	8,80211767
16	0,8	1,83E-09	100,00%	9,00090179	0,987251739	8,80211768
16	0,8	9,46E-15	100,00%	9,00090179	0,987251737	8,80211767
19	0,8	0,000186	100,00%	9,0024738	0,986951257	8,80299711

## Ek 5: B seti için geliştirilen en iyi YSA modelinin performans grafikleri



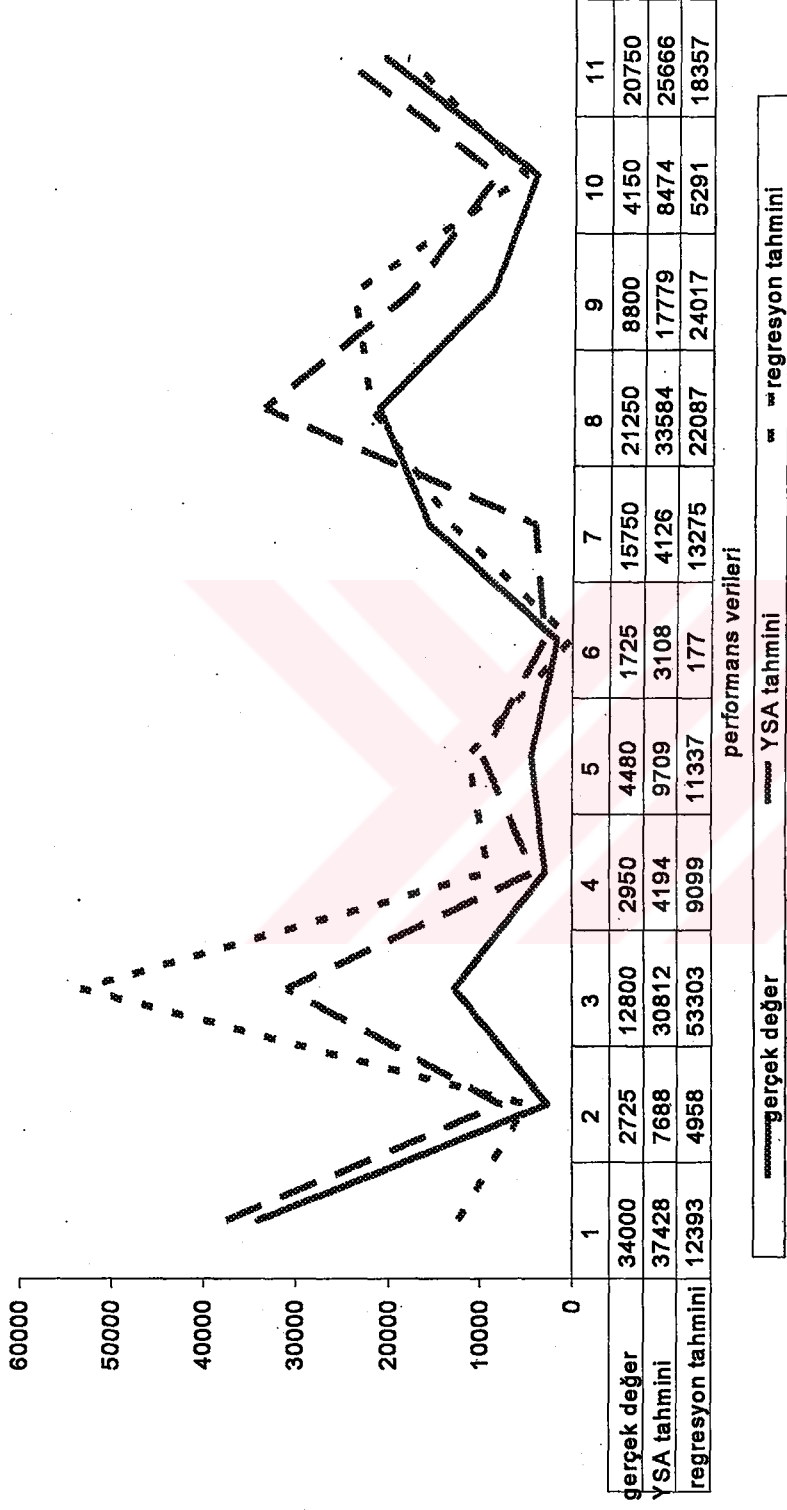


Şekil 27: YSA ve regresyon modellerinden elde edilen tahminlerin gerçek değerlerle karşılaştırılması (B seti eğitim verileri)




Şekil 28: YSA ve regresyon modellerinin mutlak hata değerlerine göre karşılaştırılması (B seti eğitim verileri)





Şekil 29: YSA ve regresyon modellerinden elde edilen tahminlerin gerçek değerlerle karşılaştırılması (B seti test verileri)



Şekil 30: YSA ve regresyon modellerinin mutlak hata değerlerine göre karşılaştırılması (B seti test verileri)