

T.C.

GEBZE YÜKSEK TEKNOLOJİ ENSTİTÜSÜ
SOSYAL BİLİMLER ENSTİTÜSÜ

YAPAY SİNİR AĞLARININ PORTFÖY
YÖNETİMİNDE KULLANILMASI

146105

M. Erkut ERDİNÇ
YÜKSEK LİSANS TEZİ
İŞLETME ANABİLİM DALI

TEZ DANIŞMANI
Yrd.Doç.Dr. Hüseyin İNCE

GEBZE

2005

..M. ERKUT ERDINC.....'in tez çalışması, GYTE Sosyal Bilimler Enstitüsü Yönetim Kurulu'nun ..24../01../2005.. tarih ve 2005../3..... sayılı kararıyla oluşturulan jüri tarafından ..S. RAFAELİ.....Anabilim Dalı'nda Yüksek Lisans Tezi olarak kabul edilmiştir.

JÜRİ

ÜYE : Yrd.Doç.Dr.Hüseyin İNCE
(Tez Danışmanı)

[Signature]

ÜYE : Doç.Dr.Halit KESKİN

[Signature]


ÜYE : Doç.Dr.Ali Ekber AKGÜN

[Signature]

ONAY

GYTE Sosyal Bilimler Enstitüsü Yönetim Kurulu'nun ..17../02../2005.. Tarih ve 2005../7..... sayılı kararı.





ÖZET

Veri Madenciliği geniş veri setlerindeki gizli modelleri keşif sürecidir. Mühendislikten haberleşmeye kadar geniş kullanım alanları vardır. Hisse seçimi, opsiyon fiyatlama ve endeksleri veya bireysel hisse fiyatlarını tahmin etme finansdaki tipik uygulamalarıdır.

Bu çalışmada Yapay Sinir Ağları'nı (YSA) kullanarak yeni bir hisse seçim aracı geliştirdik. Borsada bilgi akışı kazanç bildirileri döneminde artmaktadır. Pek çok araştırmacı borsanın kazanç bildirileri döneminde yüksek oranda değişken olduğunu belirtmişlerdir. Hedefimiz borsa endekslerinin (NASDAQ 100 ve Dow-Jones) getirilerine üstünlük sağlayan bir portföy oluşturmak için bu bilgiyi nasıl kullanabileceğimizi bulmaktır. Bu amaç YSA gibi model tanıma teknikleriyle gerçekleştirilebilir.

Bu çalışmada NASDAQ hisse endeksinde işlem gören hisse senetlerini seçtik. Her hisse için EPS, Fiyat gibi belli başlı değişkenler seçildi. İlk olarak hisse fiyatlarına bağlı olarak hisse değişim boyutunu tanımlamada k-ortalama gruplama tekniği kullanıldı. Daha sonra YSA'nın farklı tipleri kullanıldı. Bunun temel amacı YSA'nın en iyi / optimum topolojisini tanımlamaktır. Tahminin Doğruluğu (POD) , Doğruluk (ACC) gibi belli başlı istatistikleri karşılaştırmada olasılık matrisini kullandık. İstatistiklerin karşılaştırılması 7 gizli nöronlu Çok Katmanlı Algılayıcı (ÇKA)'nın diğerlerinden daha iyi performans sağladığını gösterdi.

Biz portföy yönetimine bir sınıflandırma problemi olarak baktık. Sonuçlarımız makine öğrenmesi teknikleri kullanılarak maksimum getirilerin sağlanabileceğini göstermiştir.



SUMMARY


Data mining is the process of discovering hidden patterns in large data sets. It has wide application areas from engineering to commerce. Stock selection, option pricing, and forecasting indices or individual stock prices are typical application areas in finance.

In this study, we develop a new stock selection tool using Artificial Neural Networks (ANN). Information flow in the stock market increases during the earning season. Many researchers indicate that the stock market is very volatile around the earning announcements. Our motivation is how we can use this information in order to create a winning portfolio which has to outperform the market indices (NASDAQ 100 and Dow-Jones). This can be done with pattern recognition techniques such as ANN.

In this study, we choose the stocks that are traded in NASDAQ stock market. For each stock, several variables are chosen such as EPS, Price etc. First, k-means clustering algorithm is performed in order to determine the size of the stocks in term of the stock prices. Then different types of ANN is used. The main objective of this to identify the best / optimum topology of Neural Network (NN). We use contingency tables to compute several statistics such as Probability of Detection (POD), Accuarcy (ACC) etc. Comparison of the statistics show that Multilayered Perceptrons (MLP) network with 7 hidden nörons are better than others.

We have looked at the portfolio management as a classification problem. Our results show that maximum return can be made by applying machine learning techniques.

TEŞEKKÜR



Bu çalışmaya başladığım günden itibaren gösterdiği destek ve ilgisinden dolayı değerli hocam Yrd.Doç.Dr.Hüseyin İnce'ye ve bu güne kadar eğitimim için maddi manevi her türlü imkanlarını kullanan saygıdeğer aileme teşekkür etmeyi borç bilirim.

Bu çalışmayı Mehmet Ali Erdiñ'in aziz hatırasına ithaf ediyorum.

Saygılarımla

M.Erkut Erdiñ

Mak.Müh.






İÇİNDEKİLER DİZİNİ

ÖZET	IV
SUMMARY	V
TEŞEKKÜR	VI
İÇİNDEKİLER DİZİNİ	VII
ŞEKİLLER DİZİNİ	IX
TABLolar DİZİNİ	X

1. GİRİŞ	1
2. VERİ MADENCİLİĞİ	
2.1. Tanım	3
2.2. Veri Madenciliği Kullanım Alanları	4
2.3. Veri Madenciliğindeki Problemler	5
2.4. Veri Madenciliği Modelleri	6
2.4.1. Sınıflama ve Regresyon Modelleri	7
2.4.2. Kümeleme Modelleri	8
2.5. Veri Tabanlarında Bilgi Keşif Süreci	9
2.5.1. Problemin Tanımlanması	11
2.5.2. Verilerin Hazırlanması	11
2.5.3. Modelin Kurulması ve Değerlendirilmesi	13
2.5.4. Modelin İzlenmesi	14
3. YAPAY ZEKA	
3.1. Zeka Kavramı	15
3.2. Yapay Zeka Kavramı	17
3.2.1. Yapay Zeka Tarihçesi	18
3.2.2. Yapay Zeka Teknikleri	21
3.2.2.1. Genetik Algoritmalar	21
3.2.2.2. Bulanık Mantık	23
3.2.2.3. Uzman Sistemler	24
3.3. Yapay Sinir Ağları	26
3.3.1. Biyolojik Sinir Sistemi	27


3.3.2. Yapay Sinir Ağı	29
3.3.3. Yapay Sinir Ağlarının Özellikleri	32
3.3.4. Yapay Sinir Ağı Hücresi	33
3.3.5. Aktivasyon Fonksiyonları	35
3.3.6. YSA'ların Öğrenme Algoritmalarına göre Sınıflandırılması	37
3.3.6.1. Danışmanlı Öğrenme (Supervised Learning)	38
3.3.6.2. Danışmansız Öğrenme (Unsupervised Learning)	39
3.3.7. Çok Katmanlı Algılayıcılar	40
3.3.8. Geri Yayılım Algoritması	41
3.3.9. ÇKA Ağı'nın Çalışma Prosedürü	44
3.3.10. YSA Tasarımında Dikkat Edilmesi Gereken Konular	46
3.3.10.1. Uygulama Başarısı	46
3.3.10.2. Uygulamada Karşılaşılan Güçlükler	46
3.3.10.3. Uygulamada Takip Edilmesi Gereken İşlemler	47
4. ETKİN PİYASA HİPOTEZİ	
4.1. Tanım	52
4.2. Rassal Yürüyüşler Hipotezi (Random Walks Hypothesis)	54
4.3. Etkin Piyasa Hipotezine Karşı Konan Anomaliler	56
4.3.1. Aşırı Tepki Hipotezi (Overreaction Hypothesis)	56
4.3.2. Kazancın Zamanlılığı (Timeliness of Earnings)	59
4.3.3. Firma Büyüklüğü Anomalisi	60
4.4. Kazanç Bildirileri İçin Sınıflandırma Modeli	62
5. ARAŞTIRMA UYGULAMASI	
5.1. Araştırmanın Amacı	64
5.2. Araştırmanın Kapsamı	64
5.3. Deneysel Sonuçlar	65
5.3.1. Gruplandırma	65
5.3.2. Yapay Sinir Ağı Uygulaması	67
6. SONUÇ VE ÖNERİLER	75
KAYNAKLAR	77
ÖZGEÇMİŞ	85



ŞEKİLLER DİZİNİ

Şekil

2.1. Kümeleme Modeli	8
2.2. Veri Madenciliği Süreci	10
3.1. Biyolojik Sinir Sisteminin Blok Gösterimi	28
3.2. Biyolojik Sinir Hücresi	29
3.3. Temel Yapay Sinir Ağı Hücresi	34
3.4. Eşik Aktivasyon Fonksiyonu	35
3.5. Doğrusal Aktivasyon Fonksiyonu	36
3.6. Logaritma Sigmoid Aktivasyon Fonksiyonu	37
3.7. Tanjant Hiperbolik Fonksiyonu	37
3.8. Danışmanlı Öğrenme Yapısı	39
3.9. Danışmansız Öğrenme Yapısı	39
3.10. Geri Yayılımlı ÇKA Yapısı	40
3.11. ÇKA'nın Geri Yayılım Akış Şeması	43
5.1. Yapay Sinir Ağı'nın Topolojisi	68
5.2. Gizli Katman Nöron Sayısının Değişiminin Performans İle İlişkisi	69



TABLÖLAR DİZİNİ

Tablo

3.1. Biyolojik Sinir Sistemi İle YSA Benzerliđi	30
3.2. İstatistiksel Yöntemlerle YSA'ların Terminolojik Benzeşimleri	31
5.1. Fiyat Aralığı Ve Getirilerin Tanıtımsal İstatistikleri	66
5.2. Her Sınıftaki Hisse Sayıları	66
5.3. Olasılık Tablosu	70
5.4. Eğitim Seti İçin Olasılık Tablosu	72
5.5. Test Seti İçin Olasılık Tablosu	72
5.6. Her Topolojinin Eğitim Setine Ait İstatistiksel Değerler	73
5.7. Her Topolojinin Test Setine Ait İstatistiksel Değerler	73



1. GİRİŞ

Finans dünyasında portföy yönetimi araştırmacıların uzun yıllardır üzerinde çalıştıkları önemli bir konudur. Hisse senetlerinin gelecekteki değerlerinin tahmin edilebilmesi için, geçmiş veriler ve bunun yanında her hisse senedi için kazanç bildiri tarihinden önce açıklanan ve kolaylıkla elde edilebilen haberlere ihtiyaç vardır. Geçmiş veriler, ilgi ve değişim oranı gibi ekonomik değişkenleri, büyüme ve endüstriyel üretim gibi endüstriye özel bilgileri, kar oranı gibi firmalara özel bilgileri içerebilir.

Hızla gelişen bilgisayar ve haberleşme teknolojileri, hisse senedi tahmininde yatırımcılara doğru seçimi yapmaları konusunda yeni olanaklar sunmaktadır. Yapay Sinir Ağları finans ve ekonomi dünyasında uygulanmaya başlanan son tekniklerden birisidir. Barr ve Mani (1994) Yapay Sinir Ağları'nın; S&P 500 Endeksinde hisse fiyatlarını tahmin etmede, Wilson ve Sharda (1994) ise firmanın iflasını önceden belirlemede başarıyla kullanılabildiğini göstermişlerdir. Hutchinson (1994) ve Galindo (1998), opsiyon fiyatlama üzerinde yaptıkları araştırmalarda, YSA ile klasik metotları karşılaştırmışlar ve YSA'nın diğer metotlara üstünlük sağladığını deneysel olarak ispat etmişlerdir.

Çalışmalar, finansal ve ekonomik değişkenlerle hisse senedi dönüşleri arasında tam anlamıyla doğrusal bir ilişkinin olmadığını göstermektedir (Mills, 1990). Yapay Sinir Ağları doğrusal olmayan problemlere getirebildiği güvenilir çözümlerden dolayı finans sektöründe her geçen gün daha fazla kullanılmaktadır.

Yapay Sinir Ağları, problemleri programlama yoluyla değil öğrenme yoluyla çözebilir. Dolayısıyla ağın güvenilir çözümler üretebilmesi eldeki geçmiş verilere bağlıdır; bu durum Veri Madenciliği tekniklerinin etkin kullanılmasını gerektirir.


Veri Madenciliği, eldeki verilerden üstü kapalı, çok net olmayan, önceden bilinmeyen ancak potansiyel olarak kullanışlı bilginin çıkarılmasıdır. Bu da kümeleme, veri özetleme, değişikliklerin analizi, sapmaların tespiti gibi belirli sayıda teknik yaklaşımları içerir.

Temel olarak veri madenciliği, veri setleri arasındaki desenlerin ya da düzenin, verinin analizi ve yazılım tekniklerinin kullanılması ile ilgilidir. Veriler arasındaki ilişkiyi, kuralları ve özellikleri belirlemekten bilgisayar sorumludur. Amaç, daha önceden fark edilmemiş veri desenlerini tespit edebilmektir.

Veri Madenciliği teknikleri yardımıyla, kısa dönem hisse/portföy yönetimi modeli oluşturmak oldukça zordur. Bunun nedeni, finansal piyasaların çok değişkin olması ve piyasada oluşan bilgilerin bütün yatırımcılara aynı anda ulaşmasıdır. Bu durum genellikle ‘Etkin Piyasa Hipotezi’ ile açıklanmaktadır. ‘Etkin Piyasa’ terimi ilk olarak 1961 yılında Fama tarafından ‘piyasanın yeni bilgilere hızlı uyumu’ şeklinde tanımlanmıştır. Bu tanım daha sonra yine Fama tarafından ‘varlık fiyatlarının etkin piyasada mevcut tüm bilgileri yansıtmaması’ şeklinde genişletilmiştir.

Hipoteze göre, fiyatlar yeni bilgilere hızlı bir şekilde tepki veriyorsa o piyasanın nispeten etkin olduğu söylenebilir. Aksine, bilgiler piyasada daha yavaş bir şekilde yayılıyorsa ve yatırımcıların bilgileri analiz etmesi veya tepki göstermeleri zaman alıyorsa, fiyatlar mevcut ilgili tüm bilgilerin dikkatli bir şekilde analizine dayanan değerlerden sapma gösterebileceklerdir. Bu tür piyasa nispeten etkin olmayan bir piyasa olarak isimlendirilebilir.

Çalışmamızın ikinci bölümünde Veri Madenciliği teknikleri açıklanmaya çalışılmış; üçüncü bölümde tezimizin ana temasını oluşturan Yapay Zeka ve Yapay Sinir Ağları anlatılmış; dördüncü bölümde Etkin Piyasa Hipotezi açıklanmış ve istatistiksel analizler yapılarak, kazanç bildirileri ile hisse fiyatları arasındaki ilişki ile ilgili modelimizin geçerliliği sınanmış; elde edilen sonuçlara göre beşinci bölümde Yapay Sinir Ağının topolojisi belirlenip ağ eğitilmiş; sonuç bölümünde ise analiz ve deney sonuçları irdelenmiş ve Yapay Sinir Ağları’nın portföy yönetiminde nasıl etkin kullanılabileceği tartışılmıştır.



2. VERİ MADENCİLİĞİ

2.1. Tanım

Veri madenciliği, eldeki verilerden üstü kapalı, çok net olmayan, önceden bilinmeyen ancak potansiyel olarak kullanışlı bilginin çıkarılmasıdır. Bu da; kümeleme, veri özetleme, değişikliklerin analizi, sapmaların tespiti gibi belirli sayıda teknik yaklaşımları içerir (Fayyad and Smyth, 1996).

Temel olarak veri madenciliği, veri setleri arasındaki desenlerin ya da düzenin, verinin analizi ve yazılım tekniklerinin kullanılması ile ilgilidir. Veriler arasındaki ilişkiyi, kuralları ve özellikleri belirlemekten bilgisayar sorumludur. Amaç, daha önceden fark edilmemiş veri desenlerini tespit edebilmektir (Lee and Cheng, 1998).

1995 yılında birincisi düzenlenen *Knowledge Discovery in Databases* konferansı bildiri kitabı sunuşunda, enformasyon teknolojilerinin oluşturduğu veri dağları aşağıdaki cümleler ile vurgulanmaktadır (spss.com/cleam_healthcarel.htm.)

“Dünyadaki enformasyon miktarının her 20 ayda bir ikiye katlandığı tahmin edilmektedir. Bu ham veri seli ile ne yapmamız gerekmektedir ? İnsan gözleri bunun ancak çok küçük bir kısmını görebilecektir. Bilgisayarlar bilgelik pınarı olmayı vaat etmekte, ancak veri sellerine neden olmaktadır. “

Veri Madenciliğinin günümüzde popüler olmasının sebepleri; işlemlerde otomasyona geçildiği için büyük miktarda veri üretilmesi, bir çok algoritmanın eğitim (training) ve öğrenme (learning) için çok büyük veri setine gereksinim duyması, verilerin veri depolarında (data warehouse) depolanmaya başlanması, verilerin ortak bir formda depolanması, bilgisayar sistemlerinin sürekli gelişmesi, verilerde keşfedilecek değerler olduğunun araştırmacılar tarafından kavranması şeklinde açıklanabilir (İnce, 2004).




2.2. Veri Madenciliği Kullanım Alanları

Veri madenciliği astronomi, biyoloji, finans, pazarlama, sigorta, tıp ve bir çok başka dalda uygulanmaktadır. Son 20 yıldır Amerika Birleşik Devletleri'nde çeşitli veri madenciliği algoritmalarının gizli dinlemeden, vergi kaçakçılıklarının ortaya çıkartılmasına kadar çeşitli uygulamalarda kullanıldığı bilinmektedir (Smyth and Uthuruswamy, 1996).

Bununla birlikte günümüzde veri madenciliği teknikleri özellikle işletmelerde çeşitli alanlarda başarı ile kullanılmaktadır. Bu uygulamaların başlıcaları ilgili alanlara göre aşağıda özetlenmiştir (Brachman et al., 1996).

Pazarlama:

- Müşterilerin satın alma örüntülerinin belirlenmesi,
- Müşterilerin demografik özellikleri arasındaki bağlantıların bulunması,
- Posta kampanyalarında cevap verme oranının artırılması,
- Mevcut müşterilerin elde tutulması, yeni müşterilerin kazanılması,
- Pazar sepeti analizi (*Market Basket Analysis*)
- Müşteri ilişkileri yönetimi (*Customer Relationship Management*)
- Müşteri değerlendirme (*Customer Value Analysis*)
- Satış tahmini (*Sales Forecasting*).



Bankacılık:

- Farklı finansal göstergeler arasında gizli korelasyonların bulunması,
- Kredi kartı dolandırıcılıklarının tespiti,
- Kredi kartı harcamalarına göre müşteri gruplarının belirlenmesi,
- Kredi taleplerinin değerlendirilmesi.

Finans:


- Endexleri tahmin etmede
- Döviz kurlarını tahmin etmede
- Otomatik alım-satım programları

Sigortacılık:

- Yeni poliçe talep edecek müşterilerin tahmin edilmesi,
- Sigorta dolandırıcılıklarının tespiti,
- Riskli müşteri örüntülerinin belirlenmesi.

2.3. Veri Madenciliğindeki Problemler

Veri madenciliği girdi olarak ham veriyi sağlamak üzere veri tabanlarına dayanır. Bu da veri tabanlarının dinamik, eksiksiz, geniş ve net veri içermemesi durumunda sorunlar doğurur. Diğer sorunlar da verinin konu ile uyumsuzluğundan doğabilir (Berry and Linoff, 2000).



Sınıflandırmak gerekirse başlıca sorunlar şunlardır :

- **Sınırlı Bilgi** : Veri tabanları genel olarak veri madenciliği dışındaki amaçlar için tasarlanmışlardır. Bu yüzden, öğrenme görevini kolaylaştıracak bazı özellikler bulunmayabilir.
- **Gürültü ve Eksik Değerler** : Veri özellikleri ya da sınıflarındaki hatalara gürültü (noise) adı verilir. Veri tabanlarındaki eksik bilgi ve bu yanlışlardan dolayı veri madenciliği amacına tam olarak ulaşmayabilir. Bu bilgi yanlışlığı, ölçüm hatalarından ya da öznel yaklaşımdan olabilir.
- **Belirsizlik** : Yanlışlıkların şiddeti ve verideki gürültünün derecesi ile ilgilidir. Veri tahmini bir keşif sisteminde önemli bir husustur.
- **Ebat, güncellemeler ve konu dışı sahalara** : Veri tabanlarındaki bilgiler, veri eklendikçe ya da silindikçe değişebilir. Veri madenciliği perspektifinden bakıldığında, kuralların hala aynı kalıp kalmadığı ve istikrarlılığı problemi ortaya çıkar. Öğrenme sistemi, kimi verilerin zamanla değişmesine ve keşif sisteminin verinin zamansızlığına karşın zaman duyarlı olmalıdır.

2.4. Veri Madenciliği Modelleri

Veri madenciliğinde kullanılan modeller, tahmin edici (*Predictive*) ve tanımlayıcı (*Descriptive*) olmak üzere iki ana başlık altında incelenmektedir (Glymour et al., 1997).

Tahmin edici modellerde, sonuçları bilinen verilerden hareket edilerek bir model geliştirilmesi ve kurulan bu modelden yararlanılarak sonuçları bilinmeyen veri kümeleri için sonuç değerlerin tahmin edilmesi amaçlanmaktadır. Örneğin bir banka önceki dönemlerde vermiş olduğu kredilere ilişkin gerekli tüm verilere sahip olabilir. Bu verilerde bağımsız değişkenler kredi alan müşterinin özellikleri, bağımlı değişken

değeri ise kredinin geri ödenip ödenmediğidir. Bu verilere uygun olarak kurulan model, daha sonraki kredi taleplerinde müşteri özelliklerine göre verilecek olan kredinin geri ödenip ödenmeyeceğinin tahmininde kullanılmaktadır.

Tanımlayıcı modellerde ise karar vermeye rehberlik etmede kullanılabilecek mevcut verilerdeki örüntülerin tanımlanması sağlanmaktadır. X/Y aralığında geliri ve iki veya daha fazla arabası olan çocuklu aileler ile, çocuğu olmayan ve geliri X/Y aralığından düşük olan ailelerin satın alma örüntülerinin birbirlerine benzerlik gösterdiğinin belirlenmesi tanımlayıcı modellere bir örnektir.

Veri madenciliği modellerini gördükleri işlevlere göre,

- Sınıflama (*Classification*) ve Regresyon (*Regression*),
- Kümeleme (*Clustering*),

olmak üzere iki ana başlık altında incelemek mümkündür. Sınıflama ve regresyon modelleri tahmin edici, kümeleme modeli tanımlayıcı modellerdir.


2.4.1. Sınıflama ve Regresyon Modelleri

Mevcut verilerden hareket ederek geleceğin tahmin edilmesinde faydalanılan ve veri madenciliği teknikleri içerisinde en yaygın kullanıma sahip olan sınıflama ve regresyon modelleri arasındaki temel fark, tahmin edilen bağımlı değişkenin kategorik veya süreklilik gösteren bir değere sahip olmasıdır. Ancak çok terimli lojistik regresyon (*multinomial logistic regression*) gibi kategorik değerlerin de tahmin edilmesine olanak sağlayan tekniklerle, her iki model giderek birbirine yaklaşmakta ve bunun bir sonucu olarak aynı tekniklerden yararlanılması mümkün olmaktadır. Sınıflama ve regresyon modellerinde kullanılan başlıca teknikler (David, 2001):


- Karar Ağaçları (*Decision Trees*),
- Yapay Sinir Ağları (*Artificial Neural Networks*),
- Genetik Algoritmalar (*Genetic Algorithms*),
- K-En Yakın Komşu (*K-Nearest Neighbor*),
- Bellek Temelli Nedenleme (*Memory Based Reasoning*),
- Lojistik Regresyondur (*Logistic Regression*).

2.4.2. Kümeleme Modelleri

Kümeleme modellerinde amaç, Şekil 2.1 de görüldüğü gibi küme üyelerinin birbirlerine çok benzediği, ancak özellikleri birbirlerinden çok farklı olan kümelerin bulunması ve veri tabanındaki kayıtların bu farklı kümelere bölünmesidir. Başlangıç aşamasında veri tabanındaki kayıtların hangi kümelere ayrılacağı veya kümelemenin hangi değişken özelliklerine göre yapılacağı bilinmemekte, konunun uzmanı olan bir kişi tarafından kümelerin neler olacağı tahmin edilmektedir (Spangler, May and Vargas, 1999).



Şekil 2.1. Kümeleme Modeli (Spangler et al., 1999)




2.5. Veri Tabanlarında Bilgi Keşfi Süreci


Ne kadar etkin olursa olsun hiç bir veri madenciliği algoritmasının üzerinde inceleme yapılan işin ve verilerin özelliklerinin bilinmemesi durumunda fayda sağlaması mümkün değildir. Bu nedenle aşağıda tanımlanan tüm aşamalardan önce, iş ve veri özelliklerinin öğrenilmesi / anlaşılması başarının ilk şartı olacaktır. Şekil 2.2 de ayrıntılı olarak görüldüğü gibi,

- Problemin Tanımlanması,
- Verilerin Hazırlanması,
- Modelin Kurulması ve Değerlendirilmesi,
- Modelin Kullanılması,
- Modelin İzlenmesi

veri tabanlarında bilgi keşfi sürecinde izlenmesi gereken temel aşamalardır (Fayyad et al. , 1996).



Bilgi (Knowledge)



Şekil 2.2. Veri madenciliği süreci (Fayyad et al., 1996)

2.5.1. Problemin Tanımlanması

Veri madenciliği çalışmalarında başarılı olmanın ilk şartı, uygulamanın hangi işletme amacı için yapılacağını açık bir şekilde tanımlanmasıdır. İlgili işletme amacı işletme problemi üzerine odaklanmış ve açık bir dille ifade edilmiş olmalı, elde edilecek sonuçların başarı düzeylerinin nasıl ölçüleceği tanımlanmalıdır. Ayrıca yanlış tahminlerde katlanılacak olan maliyetlere ve doğru tahminlerde kazanılacak faydalara ilişkin tahminlere de bu aşamada yer verilmelidir (Berson and Smith, 1997).

2.5.2. Verilerin Hazırlanması

Modelin kurulması aşamasında ortaya çıkacak sorunlar, bu aşamaya sık sık geri dönülmesine ve verilerin yeniden düzenlenmesine neden olacaktır. Bu durum verilerin hazırlanması ve modelin kurulması aşamaları için, bir analistin veri keşfi sürecinin toplamı içerisinde enerji ve zamanının % 50 - % 85'ini harcamasına neden olmaktadır.

Verilerin hazırlanması aşaması kendi içerisinde toplama, değer biçme, birleştirme ve temizleme, seçme ve dönüştürme adımlarından meydana gelmektedir (Anand, 1995; Rauch and Berka, 1997; Yuanhui et al., 1997).

Toplama (Collection) : Tanımlanan problem için gerekli olduğu düşünülen verilerin ve bu verilerin toplanacağı veri kaynaklarının belirlenmesi adıımıdır. Verilerin toplanmasında kuruluşun kendi veri kaynaklarının dışında, nüfus sayımı, hava durumu, merkez bankası kara listesi gibi veri tabanlarından veya veri pazarlayan kuruluşların veri tabanlarından faydalanılabilir.

Değer Biçme (Assessment) : Veri madenciliğinde kullanılacak verilerin farklı kaynaklardan toplanması, doğal olarak veri uyumsuzluklarına neden olacaktır. Bu uyumsuzlukların başlıcaları farklı zamanlara ait olmaları, kodlama farklılıkları (örneğin bir veri tabanında cinsiyet özelliğinin e/k, diğer bir veri tabanında 0/1 olarak kodlanması), farklı ölçü birimleridir. Ayrıca verilerin nasıl, nerede ve hangi koşullar altında toplandığı da önem taşımaktadır.

Bu nedenlerle, iyi sonuç alınacak modeller ancak iyi verilerin üzerine kurulabileceği için, toplanan verilerin ne ölçüde uyumlu oldukları bu adımda incelenerek değerlendirilmelidir.

Birleştirme ve Temizleme (Consolidation and Cleaning) : Bu adımda farklı kaynaklardan toplanan verilerde bulunan ve bir önceki adımda belirlenen sorunlar mümkün olduğu ölçüde giderilerek veriler tek bir veri tabanında toplanır. Ancak basit yöntemlerle ve baştan savma olarak yapılacak sorun giderme işlemlerinin, ileriki aşamalarda daha büyük sorunların kaynağı olacağı unutulmamalıdır.

Seçim (Selection) : Bu adımda kurulacak modele bağlı olarak veri seçimi yapılır. Örneğin tahmin edici bir model için, bu adım bağımlı ve bağımsız değişkenlerin ve modelin eğitiminde kullanılacak veri kümesinin seçilmesi anlamını taşımaktadır.

Verilerin görselleştirilmesine olanak sağlayan grafik araçlar ve bunların sunduğu ilişkiler, bağımsız değişkenlerin seçilmesinde önemli yararlar sağlayabilir.

Genellikle yanlış veri girişinden veya bir kereye özgü bir olayın gerçekleşmesinden kaynaklanan verilerin (*Outlier*), önemli bir uyarıcı enformasyon içerip içermediği kontrol edildikten sonra veri kümesinden atılması tercih edilir.

Modelde kullanılan veri tabanının çok büyük olması durumunda tesadüfiliği bozmayacak şekilde örnekleme yapılması uygun olabilir. Günümüzde hesaplama

olanakları ne kadar gelişmiş olursa olsun, çok büyük veri tabanları üzerinde çok sayıda modelin denenmesi zaman kısıtı nedeni ile mümkün olamamaktadır. Bu nedenle tüm veri tabanını kullanarak bir kaç model denemek yerine, tesadüfi olarak örneklenmiş bir veri tabanı parçası üzerinde bir çok modelin denenmesi ve bunlar arasından en güvenilir ve güçlü modelin seçilmesi daha uygun olacaktır.

Dönüştürme (Transformation) : Kredi riskinin tahmini için geliştirilen bir modelde, borç/gelir gibi önceden hesaplanmış bir oran yerine, ayrı ayrı borç ve gelir verilerinin kullanılması tercih edilebilir. Ayrıca modelde kullanılan algoritma, verilerin gösteriminde önemli rol oynayacaktır. Örneğin bir uygulamada bir yapay sinir ağı algoritmasının kullanılması durumunda kategorik değişken değerlerinin evet/hayır olması; bir karar ağacı algoritmasının kullanılması durumunda ise örneğin gelir değişken değerlerinin yüksek/orta/düşük olarak gruplanmış olması modelin etkinliğini artıracaktır.

2.5.3. Modelin Kurulması ve Değerlendirilmesi

Tanımlanan problem için en uygun modelin bulunabilmesi, olabildiğince çok sayıda modelin kurularak denenmesi ile mümkündür. Bu nedenle veri hazırlama ve model kurma aşamaları, en iyi olduğu düşünülen modele varılıncaya kadar yinelenen bir süreçtir.

Model kuruluş süreci denetimli (*Supervised*) ve denetimsiz (*Unsupervised*) öğrenimin kullanıldığı modellere göre farklılık göstermektedir.

Örnekten öğrenme olarak da isimlendirilen denetimli öğrenimde, bir denetçi tarafından ilgili sınıflar önceden belirlenen bir kritere göre ayrılarak, her sınıf için çeşitli örnekler verilir. Sistemin amacı verilen örneklerden hareket ederek her bir sınıfa ilişkin özelliklerin bulunması ve bu özelliklerin kural cümleleri ile ifade edilmesidir.

Öğrenme süreci tamamlandığında, tanımlanan kural cümleleri verilen yeni örneklerle uygulanır ve yeni örneklerin hangi sınıfa ait olduğu kurulan model tarafından belirlenir.

Denetimsiz öğrenmede, kümeleme analizinde olduğu gibi ilgili örneklerin gözlenmesi ve bu örneklerin özellikleri arasındaki benzerliklerden hareket ederek sınıfların tanımlanması amaçlanmaktadır.

Denetimli öğrenimde seçilen algoritmaya uygun olarak ilgili veriler hazırlandıktan sonra, ilk aşamada verinin bir kısmı modelin öğrenimi, diğer kısmı ise modelin geçerliliğinin test edilmesi için ayrılır. Modelin öğrenimi öğrenim kümesi kullanılarak gerçekleştirildikten sonra, test kümesi ile modelin doğruluk derecesi (*Accuracy*) belirlenir (Spangler et al., 1999).

2.5.4. Modelin İzlenmesi

Zaman içerisinde bütün sistemlerin özelliklerinde ve dolayısıyla ürettikleri verilerde ortaya çıkan değişiklikler, kurulan modellerin sürekli olarak izlenmesini ve gerekiyorsa yeniden düzenlenmesini gerektirecektir. Tahmin edilen ve gözlenen değişkenler arasındaki farklılığı gösteren grafikler model sonuçlarının izlenmesinde kullanılan yararlı bir yöntemdir (Fayyad and Smyth, 1996).

Bu aşamada ayrıca tüm bilgi bulma süreci çözülür. Sonuçların anlaşılmasına çalışılır, yeni bilgilerin ilginç olup olmadığı denetlenir, sonuçlar söz konusu alan açısından yorumlanır ve bunların amaç üzerindeki etkileri araştırılır (Spangler et al., 1999).

3. YAPAY ZEKA

3.1. Zeka Kavramı

Hayatımızın en gizemli ve belki de en değerli kavramı olan zekayı tarif etmek gerçekten zordur. Herkes zekanın farkındadır ama açık ve net olarak bir tarifini yapamayabilir. Bazen tanımlar birbirine benzese de çoğu zaman farklılıklar gösterebilir.

Sözlüğe bakıldığında zekanın, anlama ve kavrama yeteneği olarak tanımlandığı görülebilir. Bazen de, bir şeyi anlama, kavrama veya önemini anlama olarak da ifade edilen zeka bireysel bilgi birikimi ve deneyimlerle ilişkilidir.

En genel olarak zeka, çevreyi algılama, karar verme ve hareketleri kontrol etme yeteneğidir. Zeka ile ilgili olarak, bir çok bilim adamı ilgi alanlarına göre farklı tanımlar yapmışlardır.

- “iyi akıl yürütme, hüküm verme ve kendini iyileştirme kapasitesi”
- “algılama, sorgulama, yaratıcılık”
- “gayeli davranma, mantıklı düşünme ve çevresiyle ilişkilerinde etkili olma kapasitesi”
- “düşüncesini yeni durumlara bilinçli olarak uydurabilme yeteneği”

* ...düşünüyorum, öyleyse varım.

- “çevreye uygun tepkilerde bulunabilme”
- “öğrenme, problem çözüme, yeni ürünler ortaya çıkarma ve iletişim kurma kapasitesi”

şeklindedir (Gardner, 1993).

Gardner (1993), insan beyninin farklı bölümlerden oluştuğunu ve her bir bölümün özel işlevlere sahip olduğunu belirtmiş ve zekayı ‘değişen dünya şartlarında yaşamak ve değişimlere uyum sağlamak amacıyla her insanda kendine özgü bulunan yeteneklere ve beceriler bütünü olarak, topluma faydalı şeyler yapabilme kapasitesi’ olarak tanımlamıştır. Bu yeni yaklaşım çoklu zeka teorisi olarak da bilinmektedir. Bu teoride insanların sahip oldukları çoklu zekaların her birinin ‘yaşamak, öğrenmek ve insan olmak için etkili birer araç olduğu’ ve ‘farklı şekillerde görülebileceği ifade edilmiştir. Sonuç olarak;

- insanların çok farklı zeka gruplarına dahil olabileceği
- zekanın dinamik bir yapıda olduğu
- her insanda kendine özgü bir zeka profili olduğu
- farklı gelişim sürecine sahip olduğu
- tanımlanabilir, geliştirilebilir ve diğer zeka türleriyle etkileşim içerisinde olduğu

artık bilinmektedir.

Bu tanımlar çerçevesinde, zekayı belirli bir çerçevede tanımlamanın güçlüğü ortadadır. Zeka ancak sahip olunan bilgi birikimi, deneyim ve algılamaya göre tanımlanabilir. Bize göre ise zeka; öğrenebilme, anlama, kavrama, ilişkilendirme,

problem çözebilme, soyut düşünebilme, iyi iletişim kurma ve sonuç çıkarabilme kabiliyetidir.

3.2. Yapay Zeka Kavramı

Yapay Zeka (YZ), zeka ve düşünme gerektiren işlemlerin bilgisayarlar tarafından yapılmasını sağlayacak araştırmaların yapılması ve yeni yöntemlerin geliştirilmesi hususunda çalışan bilim dalıdır. Daha geniş anlamda YZ:

- “bilgisayarların bilgi edinme, algılama, görme, düşünme ve karar verme gibi insan zekasına özgü kapasitelerle donatılması bilimi”
- “insanların düşünüş sürecini, çeşitli makineler kullanarak taklit etme”
- “insanın düşünme yapısını anlama, bunun benzerini ortaya çıkaracak bilgisayar işlemlerini geliştirmeye çalışma”
- “programlanmış bir bilgisayarın düşünme girişimi”

olarak da tarif edilmektedir (Sağıroğlu ve ark.; 2003). YZ tanımının zeka tanımında olduğu gibi kolayca tarif edilemeyeceği ortadadır. Farklı bilim adamlarına göre tanımlar değişmektedir.

Winston ve Prendergast (1975) YZ’yı ‘makinelere daha zeki yapma, zekanın ne manaya geldiğini tam olarak anlama ve makineleri daha kullanışlı hale getirme’ olarak tanımlamaktadırlar. Searle (1990), YZ’nın insan zekasına yaklaşabilmesi için ‘biyokimyevi bir donanıma ihtiyaç olduğunu’ yalnızca böyle bir tasarımın ‘mevcut mekanik yaklaşımlardan daha üstün olacağı’ kanaatindedir.

Bir çok bilim adamı bilgisayarlar veya robotların sadece ‘sembollerini işleyerek insan zekasına ulaşamayacağını’ bunun ise ‘insan zekası ile yapay zeka arasındaki en büyük fark olduğunu’ vurgulamaktadırlar. Searle (1980), ‘hiç çiçek görmemiş ve koklamamış olan bilgisayarların çiçeğin ne olduğunu bilemeyeceğini’ ifade etmiştir.

Churchland (1990), ‘insan beyni gibi çalışan bilgisayarların tasarlanmasıyla insan zekasına yapay olarak erişilebileceğini’ düşünmektedir. Ayrıca, ‘düşünen makineler tasarlanabilir mi?’ sorusuna cevabın bu tasarımın gerçekleşmesiyle bulunabileceğini ifade etmektedir. Fiegenbaum’un (1982) bu soru hakkındaki düşünceleri olumsuzdur. Ona göre ‘bilgisayarlar bazı mantıksal süreçleri takip ederek belirli problemlere çözümler bulabilirler’. İnsanları sahip oldukları ‘ruhsal durum, hisler, sezgi gibi özelliklerden bilgisayarlar mahrum olduğu’ için ‘mantıksal süreçleri izleyerek düşünen bilgisayarların, insancıl anlamda düşünemeyeceklerini’ ileri sürmektedir.

Dreyfus ve arkadaşları (1986) ise ‘uzmanlaşmak için gerekli kurallar bütünü bir bilgisayara aktarılabilirse, bir bilgisayar belli bir konuda uzmanlaşmak için çalışmaya başlayan bir insandan daha mükemmel olarak, milyonlarca bilgiyi büyük bir hız ve doğrulukla işleyebilir, fakat hiçbir kural ve bilgi birikimi, bir uzmanın binlerce farklı durumda bizzat yaşadığı tecrübelerin kendisine kazandırdığını veremez.’ görüşünü savunmaktadır.

YZ ile ilgili olarak Penrose (1987), ‘belirli denklemleri veya algoritmaları kullanarak her problemin YZ ile çözülemeyeceğini’ fakat yine de ‘bizlerin her tür problemi çözebileceğimizi’ belirtmiştir. Bununla ‘insan beyninin algoritmik olmayan bir yaklaşım sunduğunu’ ve bu özelliğin ‘sırlarla dolu bir nitelik’ olduğunu belirtmiştir.

Sonuç olarak yapay zekayı ‘insanın düşünme, anlama, kavrama, iletişim kurma, yorumlama ve öğrenme yapılarını anlayarak benzerlerini ortaya çıkaracak yeni yaklaşımların bilgisayar yardımıyla geliştirilmesi ve insanlığın hizmetine sunulabilmesi’ olarak tanımlayabiliriz.

3.2.1. Yapay Zeka Tarihçesi

Yapay Zeka konusunda ilk çalışma McCulloch ve Pitts tarafından 1940’lı yıllarda yapılmıştır. 1943 yılında bu araştırmacılar tarafından yapay sinir sisteminin ilk matematiksel modeli geliştirilmiştir. Bu araştırmacıların önerisi; yapay sinir hücrelerini kullanan hesaplama modeli, önermeler mantığı, fizyoloji ve Turing’in

hesaplama kuramına dayanmaktadır. Çalışmalarında herhangi bir hesaplanabilir fonksiyonun sinir hücrelerinden oluşan ağlarla hesaplanabileceği ve mantıksal 've' ve 'veya' işlemlerinin gerçekleştirilebileceğini göstermiştir. Bu ağ yapılarının uygun şekilde tanımlanması halinde öğrenme becerisi kazanabileceğini de ileri sürmüşlerdir.

1949 yılında Hebb öğrenme için matematiksel bir yaklaşım geliştirmiştir. Sinir hücreleri arasındaki bağlantıların şiddetlerini değiştirmeden oluşan bu yaklaşım ile öğrenebilen sinir ağları gerçekleştirmesi kolaylaşmıştır. Geliştirilen modellerin sadece matematiksel analize bağımlı olmasından dolayı bazı işlemlerde çok büyük zorluklarla karşılaşmıştır.

1951'de Minsky, sinapsların ayarlanmasıyla belirli bir işi başarabilecek 40 nöronlu bir öğrenme sistemi sunmuştur. İlk yapay sinir ağı sistemlerinden olan SNARC, Minsky ve Edmonds tarafından 1951'de MIT'de geliştirilmiştir.

Çalışmalarını Princeton Üniversitesi'nde sürdüren McCarthy 1956 yılında Dartmouth'da iki aylık bir toplantıda, Minsky, Shannon ve Rochester'le birlikte günümüz yapay zeka çalışmalarının temelini oluşturan konularda bir çok çalışma ve tartışma yapmışlardır. Bu toplantılarda McCarthy tarafından ilk olarak 'yapay zeka' kelimesi önerilmiş ve bundan sonra da kullanılmaya başlanmıştır.

1957'de Rosenblatt, McCulloch-Pitts'in modeline öğrenme ve hatırlamayı ekleyerek genelleştirmiş ve iki katlı bir perseptronun iki farklı sınıfı ayırt edebileceğini ispatlamıştır. Bu çalışmada, nöronlar arasındaki değişim için basit prensipler kullanılarak, sınıflandırılmış modellere öğrenme yeteneği kazandıran bir ağ yapısı geliştirilmiştir. Bu yapı Hebb prensiplerine de benzemektedir. Perseptron yapısı, öğrenme yeteneğini başarılı bir şekilde açıklayan ilk modellerden birisi olarak bilinmektedir.

1959'da Widrow, Adaline (Adaptive Linear Network) olarak isimlendirilen perseptrona benzeyen bir yapay sinir sistemi geliştirmiştir.

1960'larda Grossberg, Adaptif Sistemler Merkezinde kendi kendine öğrenebilen (self-organizing), kararlılığını sağlayabilen ve verileri belirli bir aralığa otomatik olarak çekebilen YSA yapıları üzerinde çalışmalar yapmış ve ART, ART-1 ve ART-2 olarak bilinen yapıları geliştirmiştir.

Steinbuch ise 1961'de yapay sinir ağlarını bilgi kodlama alanına ilk uygulayan araştırmacı olmuştur.

1965'de Zadeh tarafından önerilen bulanık mantık teorisi ise YZ'ya yeni bir bakış açısı kazandırmıştır.

Amari 1961'de biyolojik sinir sistemi aktiviteleri ile ileri düzey matematik bilgisini çalışmalarında birleştirmiş ve ilişkilendirilmiş hafızanın (associative memory) matematiksel analizini ve yarışmacı öğrenme yaklaşımını (competitive learning) sunmuştur.

1968 yılında ise Anderson bir nöronun ağırlıklarının aktivasyon ilişkileri üzerine oluşan bir hafıza modeli önermiştir.

Fukushima ise 1969'da görüntü işleme için çok katlı bir YSA yapısı sunmuş ve Cognitron ve Neocognitron'u geliştirmiştir. O yıllarda zeka içeren sistem tasarlama çalışmalarında kullanılan temel yapılardaki bazı önemli yetersizliklerin ortaya çıkmasıyla bir çok araştırmacı çalışmalarını durdurmuştur. Bunun en büyük sebeplerinden birisi, Minsky ve Papert'in 1969 yılında yayınladıkları 'Perseptronlar' (Perceptrons) isimli kitaplarında tek katmanlı YSA'ların bazı basit problemleri bile çözemeyeceğini göstermeleri ve aynı problemin çok katmanlı YSA'larda da beklenilmesi gerektiğini belirtmeleri bu konuda yapılacak çalışmaların duraklamasına neden olmuştur.

Araştırmaların çoğunda duraksamalar olmuşsa da bazı bilim adamları çalışmalarına devam etmiştir. 1971 yılında Kohonen, ilişkili hafızalar olan LVQ'yu geliştirmiş, daha sonra da yeni versiyonları olan LVQ1, LVQ2, DLVQ gibi yaklaşımları sunmuştur.

1975’de Holland canlılarda doğal gelişimin prensibine dayanan genetik algoritmayı önermiştir.

İyi bir matematikçi ve biyolog olan Sejnowski ise 1976’da Boltzman Makinesini geliştirmiş ve buna geri-yayılım (back-propagation) algoritmasını uygulamıştır.

Hecht-Nielsen, ilk modern elektronik nöro-bilgisayar olan TRW MARK III ile PC tabanlı nöro-bilgisayar olan ANZA’yı 1982’de tasarlamışlardır.

1987’de yapılan ilk uluslar arası YSA konferansında sunulan yüzlerce çalışma ve uygulamayla artık bu alandaki çalışmalar yaygınlaşmaya başlamıştır (Haykin, 1999).

3.2.2. Yapay Zeka Teknikleri

Yapay Zeka araştırmacılarının baştan beri ulaşmak istediği ideal insan gibi düşünen ve davranan sistemler yaratmaktır. Fakat buna ulaşmanın güçlüğü anlaşıncı çalışmanın yönü rasyonel düşünen ve davranan sistemlere çevrilmiştir.

YZ teknikleri, yapay sinir ağları, bulanık mantık, sezgisel algoritmalar (genetik algoritmalar) ve uzman sistemler olarak gruplandırılırlar. Bu bölümde bulanık mantık, genetik algoritmalar ve uzman sistemler kısaca anlatılacak; tezimizde de kullandığımız yapay sinir ağları kapsamlı biçimde ele alınacaktır.

3.2.2.1. Genetik Algoritmalar

Genetik algoritmalar (GA) yönlendirilmiş rasgele araştırma algoritmalarının bir türü olup, canlılardaki doğal gelişim prensibine dayanmaktadır (Holland, 1975; Grefenstette, 1986; Reeves, 1995). Probabilistik karakterleri ve çoklu mümkün çözümleri araştırma gibi önemli özelliklere sahip olmaları ve amaç fonksiyonunun gradyentinin bilinmesine ihtiyaç duymamaları en önemli üstünlükleridir (Karaboğa, 2000). GA, evrimsel programlama, evrim stratejileri ve genetik programlama algoritmaları olduğu gibi bunların çeşitli özelliklerini barındıran çok sayıda melez yaklaşımlar da mevcuttur.

Bu algoritmalarda, araştırma uzayında bulunan bazı çözümlerin oluşturduğu bir başlangıç yoğunluğu kullanılmaktadır. Bu başlangıç yoğunluğu her kuşakta, doğal seçme ve tekrar üreme işlemleri vasıtası ile sırasıyla geliştirilir. Son kuşağın en uygun bireyi, problem için optimal bir çözüm olmaktadır. Bu çözüm her zaman optimum olmayabilir ama kesinlikle optimuma yakın olacaktır (Xu and Daley, 1992).

Genler ve kromozomlar doğal olarak türler ile ilgili bilgileri saklarlar. Bir GA'da potansiyel çözümler ile ilgili bilgiler, diziler şeklindeki sayılarla ifade edilirler. Optimizasyonun başlangıcında, çoğunlukla rasgele olarak, bir sayı üretme jeneratörü tarafından bir grup çözüm üretilir. Başlangıçta iyi bir yaklaşık çözüm için herhangi bir bilgiye ihtiyaç duyulmaması GA'nın diğer bir üstünlüğüdür (Karaboğa ve ark., 1997).

Başlangıç yoğunluğunun üretilmesini takiben her çözümün uygunluğu veya iyiliği seçilen bir uygunluk fonksiyonu kullanılarak değerlendirilir. Uygunluk fonksiyonu, eldeki veriler dikkate alınarak belirlendiği için bunun seçimi probleme bağlıdır (Liao and Chu, 1999).

Uygunluk ölçekleme işlemi, bazen daha iyiyi seçmek için elde edilen iyi çözümlerden daha iyi çözümlere kadar devam ettirilen bir işlemidir. Seçme, çaprazlama ve mutasyon gibi genetik operatörler elde edilen iyi çözümlerden denenmiş yeni çözümler üretmek için kullanılırlar. Bu iyileştirme işlemi daha önceden belirlenen bir jenerasyon sayısına veya tatmin edici bir sonuca ulaşınca kadar devam ettirilir (Xu and Daley, 1992).

Birçok seçme operatörü vardır. Bu operatörlerden ekilmiş (seeded) seçme, daha iyi çözümlere, daha fazla yaşama şansı veren yeni bir yoğunluk için çözüm anındaki yoğunluktan seçme işlemini gerçekleştirir. Rasgele (random) seçme, o andaki elde edilen çözümlerden tamamen rasgele olarak yeni bir yoğunluk oluşturur. Seçkin (elite) operatörü her zaman en iyi çözümü bir kuşaktan diğerine kopyalar. Çaprazlama operatörü var olan iki çözümün uzantılarının belirli bir noktadan itibaren yer değiştirmesi ile denenmemiş yeni iki çözüm üretir. Mutasyon operatörü ise var

olan bir çözümün herhangi bir bitinin terslendirilmesi ile yeni bir çözüm üretir (Pham and Karaboğa, 2000).

3.2.2.2. Bulanık Mantık

Bulanık Mantık (BM) kavramı ilk kez 1965 yılında Prof.Lotfi Asker Zadeh tarafından ortaya atılmıştır. Belirsizliklerin anlatımını ve belirsizliklerle çalışabilmeyi mümkün kılan bir matematiksel düzen olarak tanımlanmaktadır.

Gerçek hayatta çözümler genelde kısmen doğru veya belli bir olasılıkla doğru veya yanlış şeklinde değerlendirilir. Bulanık mantık, adından da anlaşılacağı gibi mantık kurallarının esnek veya bulanık bir şekilde uygulanmasını sağlar. Klasik mantıkta doğru ve yanlış, var ve yok yada 0 ve 1 gibi ani geçişleri yumuşatmaktadır. Bu iki değer arasında da değerler bulunduğu, insan hayatına veya kararlarına bakıldığında hemen hemen hiçbir şeyin kesinlikle doğru veya kesinlikle yanlış olmadığı göz önüne alınırsa böyle bir yaklaşımın farklılığı daha açık ortaya çıkmaktadır. Bu yeni yaklaşıma klasik mantığın gerçek dünya problemlerini çözmede yeterli olmadığı durumlar dolayısıyla ihtiyaç duyulmuştur (Kosko, 1997).

BM teorisinin temeli bulanık küme teorisiyle açıklanmaktadır. Örneğin ‘çok güzel’ kavramını inceleyecek olursak, bu kavram kişiden kişiye değişiklik gösterebilir. Kesin sınırlar söz konusu olmadığı için de bu kavram, matematiksel olarak da kolayca formüle edilemez. Ama genel olarak bazı kriterler ile sayısal olarak güzellik sınırları belirlenebilir. Bu ise, kendi aitlik fonksiyonu ile temsil edilebilir. Aitlik fonksiyonu 0 ile 1 arasında her değer alabilir. Böyle bir aitlik fonksiyonu ile ‘kesinlikle ait’ veya ‘kesinlikle ait değil’ arasında istenilen hassasiyette değerler elde etmek mümkündür (Karaboğa ve ark.,2001).

Bulanık mantıkta kümeler kadar önemli bir diğer kavramda dilsel değişken kavramıdır. Bir dilsel değişkenin değerleri bulanık kümeler ile ifade edilir. Az, biraz, çok, çok fazla, çok az gibi kavramlar kullanılabilir. Bu kavramlar ile bir çamaşır veya bulaşık makinesinin ne zaman ve hangi seçeneklerde devreye



girebileceği daha esnek olan karar verme mekanizmaları tasarım mühendislerine yardımcı olabilir (Bağış ve ark., 2001).

Bulanık mantıkta, klasik mantıkta olduğu gibi operatörler vardır (örneğin ve, veya, değil); ancak bunlar kendine haz işlemlerdir. Mesela başka yaklaşımlar da olmasına rağmen ‘ve’ işlemi genelde çarpma olarak ifade edilir. ‘veya’ işlemi de birden çıkarma şeklinde ifade edilir. Ancak bunlar en basit yaklaşımlardır (Karaboğa ve ark.2001).

Bu teorelin insan düşünme tarzına yakın olması, uygulanışı sırasında bir matematik modele ihtiyaç duyulmaması, programlanmasının basit olması dolayısıyla ucuza mal olması, donanım olarak gerçekleştirilebilmesi bilinen üstünlükleri iken, uygulamada kullanılan kuralların oluşturulmasının uzmana bağıllığı, üyelik fonksiyonlarının deneme-yanılma yolu ile bulunmasından dolayı uzun zaman alabilmesi, kararlılık analizinin yapılmasının zorluğu ise bilinen dezavantajlarıdır (Kaplan, 2001).

3.2.2.3. Uzman Sistemler

Bilgisayar bilimleri alanında yaşanmakta olan hızlı gelişme ister istemez bilgisayar tabanlı sistemlerle çalışan kişi ve kuruluşları da etkilemekte ve gelişime ayak uydurmayı zorunlu kılmaktadır. Bilginin öneminin artması ile o bilgiye ulaşabilmeyi ve bilgiyi işleyen ve farklı sonuçlar çıkarabilen karar mekanizmalarına duyulan ihtiyaçlar da artmıştır.

Uzman Sistemler (US), belirli bir alanda sadece o alanla ilgili bilgilerle donatılmış ve problemlere o alanda uzman bir kişinin getirdiği çözümler getirebilen bilgisayar programlarıdır. İyi tasarlanmış sistemler belirli problemlerin çözümünde uzman insanların düşünme metodolojilerini taklit ederler. Sistemin bir veya daha fazla uzman bilgilerini barındırmasından dolayı ‘uzman sistem’ adını almıştır. Burada amaç bir uzman insandan daha iyi bir uzman sistem geliştirmektir. Böyle bir sisteme sahip olmak kişiyi uzman yapmaz fakat bir uzmanın yapacağı işin bir kısmının veya tamamının yapılmasını kolaylaştırabilir (Sağıroğlu ve ark.,2003).

DENDRAL ile başlayan çalışmalardan sonra 1976 yılında Stanford Üniversitesinde Fiegenbaum ve arkadaşları tarafından ilk uzman sistem olan MYCIN, bakteriyolojik ve menenjitik hastalıkların tedavisine yönelik bir sistemdir. Bu sistemde, hastanın geçmiş bilgileri, laboratuvar sonuçları, semptomların sorgulanması ve bu bilgilerin derlenmesi ile teşhis konulabilmiş, reçete yazımı ve tedavi süreçlerinin belirlenmesi sağlanmıştır. MYCIN'e belirtilen verilerin girilmesiyle, niçin ve nasıl soruları sistem tarafından cevaplandırılmakta, sistem kullanıcı ile etkileşimli olarak çalışmaktadır (Winston, 1992).

US'lerin kullanılmasıyla, maliyet ve işleyiş hataları azaltılabilir, verimlilik artışı sağlanabilir, kalite artışı veya iyileştirilmesi gerçekleştirilebilir, esneklik ve daha ucuz sistem kurulumu gerçekleştirilebilir ve tehlikeli çevrelerde iş veya işlemler yapılabilir. Bu sayede güvenilirlik artırılır, cevap verme süresi azaltılır, tam ve kesin olmayan bilgi ile çalışılabilir, sınırlı da olsa bazı problemlerin çözümü kolaylaştırılabilir (Konar, 2000; Jackson, 1999).

Bu üstünlükleri yanında US'lerin gerçekleştirilmesinde bazı güçlükler de vardır (Russel and Norvig, 1995). Bu güçlükler:

- İnsanlardan sisteme uygulanabilecek bilgi almak zordur ve alınan bilgiler her zaman okunabilir uygunlukta olmayabilir.
- Uzman sistemlerin çalışma alanı sınırlı olabilir.
- Sistemi oluşturacak ve kuracak uzmanların azlığı ve yüksek ücret talepleri sistemin maliyetini yükseltebilir.
- Farklı uzman bilgilerinde çelişkilerle karşılaşılabilir.

Uzman Sistemler modern bilgi sistemleri olmasına rağmen, ancak karar verme kurallarının çok açık ve bilginin güvenilir olduğu problemlerde başarı ile uygulanabilmektedir. Son yıllarda problemlerin çözümünde bulanık kümeler (fuzzy sets) ve yapay sinir ağları (artificial neural networks) gibi yapay zeka teknikleri ile beraber kullanılmaktadırlar. US ler bilgisayar destekli tasarımdan, hastalık teşhisine,



arıza ve üretim hatalarının tespitinden, endüstriyel robotlara, iş ve süreç planlamadan, ekonomik analizlere, askeri uygulamalardan uzay çalışmalarına kadar bir çok alanda başarıyla kullanılmaktadır.

3.3. Yapay Sinir Ağları

Yapay Sinir Ağları (YSA), beynin fizyolojisinden yararlanılarak oluşturulan bilgi işleme modelleridir. Literatürde 100'den fazla yapay sinir ağı modeli vardır. Bazı bilim adamları, beynimizin güçlü düşünme, hatırlama ve problem çözme yeteneklerini bilgisayara aktarmaya çalışmışlardır. Bazı araştırmacılar ise, beynin fonksiyonlarını kısmen yerine getiren bir çok modelleri oluşturmaya çalışmışlardır .

YSA'ların öğrenme özelliği, araştırmacıların dikkatini çeken en önemli özelliklerden birisidir. Çünkü herhangi bir olay hakkında girdi ve çıktılar arasındaki ilişkiyi, doğrusal olsun veya olmasın, elde bulunan mevcut örneklerden öğrenerek daha önce hiç görülmemiş olayları, önceki örneklerden çağrışım yaparak ilgili olaya çözümler üretebilme özelliği YSA'lardaki zeki davranışın da temelini teşkil eder .

1943 yılında bir nörobiyolojist olan Warren McCulloch ve bir istatistikçi olan Walter Pitts, "*Sinir Aktivitesindeki Düşüncelere Ait Bir Mantıksal Hesap*" başlıklı bir makale ile ilk dijital bilgisayarlara ışık tutmuştur. John Von Neumann bu makaleyi, "elektronik beyinler" için bir kopya olarak görmüştür. Yapay zeka alanındaki araştırmacılar içerisinde istisnai bir yeri olan Marvin Minsky, bu makaleden aldığı ilhamla makroskobik zeka fikrini ortaya atmış ve uzman sistemlerin doğmasına neden olmuştur. Bronx Yüksek Bilim Okulu'ndan Frank Rosenblatt, gözün hesaplamaları ile ilgilenmiştir. Bu bilim adamları, öğrenmenin ve zekanın herhangi bir özelliğinin simülasyonunda bilgisayarların aktif olarak nasıl kullanılabileceğini, 1956 yılında düzenlemiş oldukları ilk yapay zeka konferansında tartışmışlardır.

1959'da, Stanford üniversitesinden Bernard Widrow, basit nöron benzeri elemanlara dayanan ve "adaline" (Adaptive Linear Neuron) olarak adlandırılan bir adaptif lineer 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, ayırık bir çıkış yerine sürekli bir çıkış üretmek için geliştirilmiştir. Widrow, telefon hatları üzerindeki ekoları elimine etmeye yarayan adaptif filtreleri geliştirmede, adaptif lineer eleman algoritmasını kullanmıştır. Bununla ilk defa YSA'lar gerçek bir probleme uygulanmıştır .

Helsinki Teknik Üniversitesi'nden Teuvo Kohonen, 1970'lerin ilk yıllarında adaptif öğrenme ve birleşik hafızalar üzerine temel çalışmalar yapmış ve bulduğu sonuçlar danışmansız öğrenme metotlarının gelişmesine ışık tutmuştur .

Minsky ve Papert'in 'Perseptron' isimli kitaplarında, YSA'nın temel olarak ilgi çekici konular olmadığını belirtmeleri bir çok araştırmacının bu alanda çalışmaktan vazgeçmelerine sebebiyet vermiştir. YSA konusunda çalışmaya devam eden Grossberg, YSA modellerini yapılandırmak için nörolojik verinin kullanılması, algı ve hafıza için YSA tabanlı mekanizmaların önerilmesi, belirgin eşitliklerle bütünleşen bir sinaptik model için bir ilişkilendirici kural üzerinde çalışmıştır.

1982 yılında ilgi çeken bir başka gelişme, moleküller biyolojiden beyin kuramcılığına geçiş yapan bir model Caltech fizikçisi Hopfield tarafından sunulmuştur. Kendi adıyla anılan bir ağ yapısı mevcuttur ve bir çok alana uygulanmıştır.

1987 yılında yapılan ilk yapay sinir ağları sempozyumundan sonra YSA uygulamaları yaygınlaşmıştır. Günümüzde, YSA'larla ilgili araştırmalar yapan çok sayıda bilim adamı ve araştırma grupları vardır. Farklı bilim ve ilgi alanlarında çalışan birçok araştırmacı, birçok yeni gelişmeleri sunmaya devam edeceklerdir.

Takip eden bölümlerde biyolojik nörondan yapay nörona geçiş anlatılmaktadır.

3.3.1. Biyolojik Sinir Sistemi


Biyolojik sinir sistemi, merkezinde sürekli olarak bilgiyi alan, yorumlayan ve uygun bir karar üreten beynin (merkezi sinir ağı) bulunduğu 3 katmanlı bir sistem

olarak açıklanır. Alıcı sinirler (receptor) organizma içerisinde ya da dış ortamlardan algıladıkları uyarıları, beyne bilgi ileten elektriksel sinyallere dönüştürür. Tepki sinirleri (effector) ise, beyinin ürettiği elektriksel darbeleri organizma çıktısı olarak uygun tepkilere dönüştürür (Arbib, 1987). Şekil 3.1 de bir sinir sisteminin blok gösterimi verilmiştir.



Şekil 3.1. Biyolojik sinir sisteminin blok gösterimi (Arbib, 1987)

Merkezi sinir ağında bilgiler, alıcı ve tepki sinirleri arasında ileri ve geri besleme yönünde değerlendirilerek uygun tepkiler üretilir. Bu yönüyle biyolojik sinir sistemi, kapalı çevrim denetim sisteminin karakteristiklerini taşır. Merkezi sinir sisteminin temel işlem elemanı, sinir hücresidir (nöron) ve insan beyinde yaklaşık 10 milyar sinir hücresi olduğu tahmin edilmektedir. Sinir hücresi; hücre gövdesi, dendritler ve axonlar olmak üzere 3 bileşenden meydana gelir. Dendritler, diğer hücrelerden aldığı bilgileri hücre gövdesine bir ağaç yapısı şeklinde ince yollarla iletir. Axonlar ise elektriksel darbeler şeklindeki bilgiyi hücreden dışarı taşıyan daha uzun bir yoldur. Axonların bitimi, ince yollara ayrılabilir ve bu yollar, diğer hücreler için dendritleri oluşturur (Eggermont, 1990). Şekil 3.2 de görüldüğü gibi axon-dendrite bağlantı elemanı synapse olarak söylenir.



Şekil 3.2. Biyolojik Sinir Hücresi (Eggermont, 1990)

Synapse gelen ve dendriteler tarafından alınan bilgiler genellikle elektriksel darbelerdir ancak, synapsedeki kimyasal ileticilerden etkilenir. Belirli bir sürede bir hücreye gelen girişlerin değeri, belirli bir eşik değerine ulaştığında hücre bir tepki üretir. Hücrenin tepkisini artırıcı yöndeki girişler uyarıcı, azaltıcı yöndeki girişler ise önleyici girişler olarak söylenir ve bu etkiyi synapse belirler (Swingler, 1996).

İnsan beyninin 10 milyar sinir hücresinden ve 60 trilyon synapse bağlantısından oluştuğu düşünülürse son derece karmaşık ve etkin bir yapı olduğu anlaşılır. Diğer taraftan bir sinir hücresinin tepki hızı, günümüz bilgisayarlarına göre oldukça yavaş olmakla birlikte duyuşal bilgileri son derecede hızlı değerlendirebilmektedir. Bu nedenle insan beyni; öğrenme, birleştirme, uyarılma ve genelleştirme yeteneği nedeniyle son derece karmaşık, doğrusal olmayan ve paralel dağılmış bir bilgi işleme sistemi olarak tanımlanabilir (Sağıroğlu ve ark., 2003).

3.3.2. Yapay Sinir Ağı (YSA)

Beynin üstün özellikleri, bilim adamlarını üzerinde çalışmaya zorlamış ve beynin nörofiziksel yapısından esinlenerek matematiksel modeli çıkarılmaya çalışılmıştır. Beynin bütün davranışlarını tam olarak modelleyebilmek için fiziksel bileşenlerinin doğru olarak modellenmesi gerektiği düşüncesi ile çeşitli yapay hücre ve ağ modelleri geliştirilmiştir. Böylece Yapay Sinir Ağları denen yeni ve günümüz bilgisayarlarının algoritmik hesaplama yönteminden farklı bir bilim alanı ortaya çıkmıştır. Yapay Sinir Ağları; yapısı, bilgi işleme yöntemindeki farklılık ve

uygulama alanları nedeniyle çeşitli bilim dallarının da kapsam alanına girmektedir (Konar, 2000).

Tablo 3.1. Biyolojik sinir sistem ile YSA benzerliği (Öztemel, 2003)

SİNİR SİSTEMİ	YSA SİSTEMİ
Neuron	İşlem elemanı
Dendrit	Toplama fonksiyonu
Hücre gövdesi	Transfer fonksiyonu
Aksonlar	Eleman çıkışı
Sinapslar	Ağırlıklar

Tablo 3.2. İstatistiksel yöntemlerle YSA ların terminolojik benzeşimleri (Öztemel, 2003)

İstatistiksel	YSA
Model	Ağ
Tahmin	Öğrenme
Regesyon	Danışmanlı öğrenme
İnterpolasyon	Genelleştirme
Gözlem	Öğrenme algoritması
Parametre	Ağ parametreleri
Bağımsız değişken	Giriş verileri
Bağımlı değişken	Çıkış verileri
Sınır regresyonu	Ağırlık budama işlemi

Genel anlamda YSA, beynin bir işlevi yerine getirme yöntemini modellemek için tasarlanan bir sistem olarak tanımlanabilir. YSA, yapay sinir hücrelerinin birbirleri ile çeşitli şekillerde bağlanmasından oluşur ve genellikle katmanlar şeklinde düzenlenir. Donanım olarak elektronik devrelerle yada bilgisayarlarda yazılım olarak gerçekleştirilebilir. Beynin bilgi işleme yöntemine uygun olarak YSA, bir öğrenme sürecinden sonra bilgiyi toplama, hücreler arasındaki bağlantı ağırlıkları ile bu bilgiyi saklama ve genelleme yeteneğine sahip paralel dağılmış bir işlemcidir.



3.3.3. Yapay Sinir Ağlarının Özellikleri

Yukarıda verilen açıklamalardan, YSA' nın hesaplama ve bilgi işleme gücünü, paralel dağılmış yapısından, öğrenebilme ve genelleme yeteneğinden aldığı söylenebilir. Genelleme, eğitim yada öğrenme sürecinde karşılaşılmayan girişler için de YSA' nın uygun tepkileri üretmesi olarak tanımlanır. Bu üstün özellikleri, YSA' nın karmaşık problemleri çözebilme yeteneğini gösterir (Rumelhart et al., 1994).

Günümüzde birçok bilim alanında YSA, aşağıdaki özellikleri nedeniyle etkin olmuş ve uygulama yeri bulmuştur (Haykin, 1999).

YSA' nın temel işlem elemanı olan hücre doğrusal değildir. Dolayısıyla hücrelerin birleşmesinden meydana gelen YSA da doğrusal değildir ve bu özellik bütün ağa yayılmış durumdadır. Bu özelliği ile YSA, doğrusal olmayan karmaşık problemlerin çözümünde en önemli araç olmuştur.

YSA' nın arzu edilen davranışı gösterebilmesi için amaca uygun olarak ayarlanması gerekir. Bu, hücreler arasında doğru bağlantıların yapılması ve bağlantıların uygun ağırlıklara sahip olması gerektiğini ifade eder. YSA' nın karmaşık yapısı nedeniyle bağlantılar ve ağırlıklar önceden ayarlı olarak verilemez yada tasarlanamaz. Bu nedenle YSA, istenen davranışı gösterecek şekilde ilgilendiği problemde aldığı eğitim örneklerini kullanarak problemi öğrenmelidir.

YSA, ilgilendiği problemi öğrendikten sonra eğitim sırasında karşılaşmadığı test örnekleri için de arzu edilen tepkiyi üretebilir. Örneğin, karakter tanıma amacıyla eğitilmiş bir YSA, bozuk karakter girişlerinde de doğru karakterleri verebilir yada bir sistemin eğitilmiş YSA modeli, eğitim sürecinde verilmeyen giriş sinyalleri için de sistemle aynı davranışı gösterebilir.

YSA, ilgilendiği problemdeki değişikliklere göre ağırlıklarını ayarlar. Yani, belirli bir problemi çözmek amacıyla eğitilen YSA, problemdeki değişimlere göre tekrar eğitilebilir, değişimler devamlı ise gerçek zamanda da eğitime devam

edilebilir. Bu özelliği ile YSA, uyarlamalı örnek tanıma, sinyal işleme, sistem tanılama ve denetim gibi alanlarda etkin olarak kullanılır.

YSA, çok sayıda hücrenin çeşitli şekillerde bağlanmasından oluştuğundan paralel dağılmış bir yapıya sahiptir ve ağına sahip olduğu bilgi, ağıdaki bütün bağlantılar üzerine dağılmış durumdadır. Bu nedenle, eğitilmiş bir YSA'nın bazı bağlantılarının hatta bazı hücrelerinin etkisiz hale gelmesi, ağına doğru bilgi üretmesini önemli ölçüde etkilemez. Bu nedenle, geleneksel yöntemlere göre hatayı tolere etme yetenekleri son derece yüksektir.

YSA, paralel yapısı nedeniyle büyük ölçekli entegre devre (VLSI) teknolojisi ile gerçekleştirilebilir. Bu özellik, YSA'nın hızlı bilgi işleme yeteneğini artırır ve gerçek zamanlı uygulamalarda arzu edilir.


YSA'nın temel işlem elemanı olan hücrenin yapısı ve modeli, bölüm 3.3.4'de açıklandığı gibi bütün YSA yapılarında yaklaşık aynıdır. Dolayısıyla, YSA'nın farklı uygulama alanlarındaki yapıları da standart yapıdaki bu hücrelerden oluşacaktır. Bu nedenle, farklı uygulama alanlarında kullanılan YSA'ları benzer öğrenme algoritmalarını ve teorilerini paylaşabilirler. Bu özellik, problemlerin YSA ile çözümünde önemli bir kolaylık getirecektir.

3.3.4. Yapay Sinir Ağı Hücresi

Temel bir yapay sinir ağı hücresi biyolojik sinir hücresine göre çok daha basit bir yapıya sahiptir. En temel nöron modeli aşağıdaki şekilde görülmektedir. Yapay sinir ağı hücresinde temel olarak dış ortamdan ya da diğer nöronlardan alınan veriler yani girişler, ağırlıklar, toplama fonksiyonu, aktivasyon fonksiyonu ve çıkışlar bulunmaktadır. Dış ortamdan alınan veri, ağırlıklar aracılığıyla nörona bağlanır ve bu ağırlıklar ilgili girişin etkisini belirler. Toplam fonksiyonu ise net girişi hesaplar, net giriş, girişlerle bu girişlerle ilgili ağırlıkların çarpımının bir sonucudur. Aktivasyon fonksiyonu işlem süresince net çıkışı hesaplar ve bu işlem aynı zamanda nöron çıkışını verir. Genelde aktivasyon fonksiyonu doğrusal olmayan (nonlinear) bir



fonksiyondur. Şekilde görülen b bir sabittir, bias veya aktivasyon fonksiyonunun eşik değeri olarak adlandırılır. Nöronun matematiksel modeli şöyledir (Williams, 1989):



Şekil 3.3. Temel yapay sinir ağı hücresi.(Haykin, 1999)

Çıkış, $o = f(W.X + b)$

şeklinde nöron çıkışı hesaplanır. Buradaki W ağırlıklar matrisi, X ise girişler matrisidir. n giriş sayısı olmak üzere;

$$W = w_1, w_2, w_3, \dots, w_n$$

$$X = x_1, x_2, x_3, \dots, x_n$$

Şeklinde yazılabilir. Formalize edersek;


$$net = \sum_{i=1}^n w_i x_i + b \text{ ve } o = f(net)$$

$$o = f\left(\sum_{i=1}^n w_i x_i + b\right) \text{ şeklinde de yazılabilir.}$$

Yukarıdaki formülde görülen f aktivasyon fonksiyonudur. Genelde non-lineer olan aktivasyon fonksiyonunun çeşitli tipleri vardır.


3.3.5. Aktivasyon Fonksiyonları

Aşağıdaki şekilde eşik aktivasyon fonksiyonunun grafiği görülmektedir. Eşik aktivasyon fonksiyonu eğer net değeri sıfırdan küçükse 0, sıfırdan daha büyük bir değer ise net çıkışında +1 değeri verir. Eşik aktivasyon fonksiyonunun -1 ile +1 arasında değişeni ise signum aktivasyon fonksiyonu olarak adlandırılır. Signum aktivasyon fonksiyonu, net giriş değeri sıfırdan büyükse +1, sıfırdan küçükse -1, sıfıra eşitse sıfır değerini verir.



Şekil 3.4. Eşik aktivasyon fonksiyonu.


Aşağıdaki şekilde doğrusal aktivasyon fonksiyonu görülmektedir. Lineer aktivasyon fonksiyonunun çıkışı girişine eşittir. Sürekli çıkışlar gerektiği zaman çıkış katmanındaki aktivasyon fonksiyonunun lineer aktivasyon fonksiyonu olabildiğine dikkat edilmelidir.



Şekil 3.5. Doğrusal aktivasyon fonksiyonu

$f(x) = x$ şeklinde ifade edilir.

Aşağıdaki şekilde logaritma sigmoid transfer fonksiyonu görülmektedir. Lojistik fonksiyon olarak da adlandırılmaktadır. Bu fonksiyonunun lineer olmamasından dolayı türevi alınabilmektedir böylece daha sonraki bölümlerde görülecek olan geri yayınlımlı ağlarda kullanmak mümkün olabilmektedir.




Şekil 3.6. Logaritma Sigmoid aktivasyon fonksiyonu.

Lojistik fonksiyonu,

$$f(x) = \text{lojistik}(x) = \frac{1}{1 + \exp(-\beta x)}$$

şeklinde ifade edilir. Buradaki β eğim sabiti olup genelde 1 olarak seçilmektedir. Diğer bir aktivasyon fonksiyonu olan hiperbolik tanjant aktivasyon fonksiyonu da lineer olmayan türevi alınabilir bir fonksiyondur. +1 ile -1 arasında çıkış değerleri üreten bu fonksiyon lojistik fonksiyona benzemektedir. Denklemi aşağıda görüldüğü gibidir.



Şekil 3.7. Tanjant Hiperbolik fonksiyonu

$$f(x) = \tanh(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}}$$

Bu aktivasyon fonksiyonlarından başka fonksiyonlar da vardır. Yapay sinir ağında hangi aktivasyon fonksiyonunun kullanılacağı probleme bağlı olarak değişmektedir (Geman, 1992 ; Goodacre, 1994; Lippmann, 1995). Yukarıda verilen fonksiyonlar en genel aktivasyon fonksiyonlarıdır.


3.3.6. YSA'ların Öğrenme Algoritmalarına Göre Sınıflandırılması

Öğrenme; gözlem, eğitim ve hareketin doğal yapıda meydana getirdiği davranış değişikliği olarak tanımlanmaktadır. O halde, birtakım metot ve kurallar, gözlem ve eğitime göre ağıdaki ağırlıkların değiştirilmesi sağlanmalıdır. Bunun için genel olarak


üç öğrenme metodundan ve bunların uygulandığı değişik öğrenme kurallarından söz edilebilir. Bu öğrenme kuralları aşağıda açıklanmaktadır.

3.3.6.1. Danışmanlı Öğrenme (Supervised Learning)

Bu tip öğrenmede, YSA'ya örnek olarak bir doğru çıkış verilir. İstenilen ve gerçek çıktı arasındaki farka (hataya) göre nöronlar arası bağlantıların ağırlığını en uygun çıkışı elde etmek için sonradan düzenlenebilir. Bu sebeple danışmanlı öğrenme algoritmasının bir “öğretmene” veya “danışmana” ihtiyacı vardır. Şekil 3.8 de danışmanlı öğrenme yapısı gösterilmiştir. Widrow-Hoff tarafından geliştirilen delta kuralı ve Rumelhart ve McClelland tarafından geliştirilen genelleştirilmiş delta kuralı veya geri besleme (back propagation) algoritması danışmanlı öğrenme algoritmalarına örnek olarak verilebilir (Haykin, 1999).




Şekil 3.8. Danışmanlı öğrenme yapısı (Sağıroğlu ve ark., 2003)



3.3.6.2. Danışmansız Öğrenme (Unsupervised Learning)

Girişe verilen örnekten elde edilen çıkış bilgisine göre ağ sınıflandırma kurallarını kendi kendine geliştirmektedir. Bu öğrenme algoritmalarında, istenilen çıkış değerinin bilinmesine gerek yoktur. Öğrenme süresince sadece giriş bilgileri verilir. Ağ daha sonra bağlantı ağırlıklarını aynı özellikleri gösteren desenler (patterns) oluşturmak üzere ayarlar. Şekil 3.9 de danışmansız öğrenme yapısı gösterilmiştir. Grossberg tarafından geliştirilen ART (Adaptive Resonance Theory) veya Kohonen tarafından geliştirilen SOM (Self Organizing Map) öğrenme kuralı danışmansız öğrenmeye örnek olarak verilebilir (Haykin, 1999).




Şekil 3.9. Danışmansız öğrenme yapısı (Sağıroğlu ve ark., 2003)

3.3.7. Çok Katmanlı Algılayıcılar

Bir çok katmanlı algılayıcı sinir ağı modeli, Şekil 3.10 da gösterilmiştir. Bu ağ modeli özellikle mühendislik uygulamalarında en çok kullanılan sinir ağı modeli olmuştur. Bir çok öğretim algoritmasının bu ağı eğitmede kullanılabilir olması, bu modelin yaygın kullanılmasının sebebidir. Bir ÇKA modeli, bir giriş, bir veya daha fazla ara ve bir de çıkış katmanından oluşur. Bir katmandaki bütün işlem elemanları bir üst katmandaki bütün işlem elemanlarına bağlıdır. Bilgi akışı ileri doğru olup geri besleme yoktur. Bunun için ileri beslemeli sinir ağı modeli olarak adlandırılır. Giriş katmanında herhangi bir bilgi işleme yapılmaz. Buradaki işlem elemanı sayısı tamamen uygulanan problemler giriş sayısına bağlıdır. Ara katman sayısı ve ara

katmanlardaki işlem elemanı sayısı ise, deneme-yanılma yolu ile bulunur. Çıkış katmanındaki eleman sayısı ise yine uygulanan probleme dayanılarak belirlenir (Fukushima, 1988).



Şekil 3.10. Geri yayımlı ÇKA yapısı (Fukushima, 1988)

ÇKA ağlarında, ağa bir örnek gösterilir ve örnek neticesinde nasıl bir sonuç üreteceği de bildirilir (danışmanlı öğrenme). Örnekler giriş katmanına uygulanır, ara katmanlarda işlenir ve çıkış katmanından da çıkışlar elde edilir. Kullanılan eğitim algoritmasına göre, ağın çıkışı ile arzu edilen çıkış arasındaki hata tekrar geriye doğru yayılarak hata minimuma düşünceye kadar ağın ağırlıkları değiştirilir. İleri beslemeli ağlar, en genel anlamıyla giriş uzayıyla çıkış uzayı arasında statik haritalama yapar. Bir andaki çıkış, sadece o andaki girişin bir fonksiyonudur (Gardner, 1993).

3.3.8. Geri Yayılım Algoritması

Bir çok uygulamalarda kullanılmış en yaygın öğretim algoritmasıdır. Anlaşılması kolay ve matematiksel olarak ispatlanabilir olmasından dolayı en çok tercih edilen öğretim algoritmasıdır. Bu algoritma, hataları geriye doğru çıkıştan girişe azaltmaya çalışmasından dolayı geri yayılım ismini almıştır (Jackson, 1999).

Tipik çok katlı geri yayılım ağı, daima; bir giriş tabakası, bir çıkış tabakası ve en az bir gizli tabakaya sahiptir. Gizli tabakaların sayısında teorik olarak bir sınırlama yoktur. Fakat genel olarak bir veya iki tane bulunur. Desen sınıflandırma problemlerini çözmek için maksimum dört tabakaya (üç gizli ve bir çıkış tabakası) gereksinim duyulduğuna işaret eden bazı çalışmalar yapılmıştır. Geri yayılım algoritması, gradyen azalan ve ÇKA'ları eğitmede en çok kullanılan temel bir algoritmadır (Konar, 2000). Bu algoritmanın akış şeması Şekil 3.11'de verilmiştir.

Eğitme işlemi ve eğitimden sonraki test işlemi bu akışa göre yapılır. Bu algoritma ile, i ve j kat işlem elemanları arasındaki ağırlıklardaki $\Delta w_{ji}(t)$ değişikliği hesaplanır. Bu ifade,

$$\Delta w_{ji}(t) = \eta \delta_j x_i + \alpha \Delta w_{ji}(t-1) \quad (3.1)$$

olarak verilir. Eşitlik (3.1)'de η öğrenme katsayısı, α momentum katsayısı ve δ_j ara veya çıkış katındaki herhangi bir j nöronuna ait bir faktördür. Öğrenme katsayısı ağırlıkların değişim miktarını; momentum katsayısı ise ÇKA ağının öğrenmesi esnasında yerel bir optimum noktaya takılıp kalmaması için ağırlık değişim değerinin belirli bir oranda bir sonraki değişime eklenmesini sağlarlar. Çıkış katı için bu faktör aşağıdaki şekilde verilir.


$$\delta_j = \frac{\partial f}{\partial net_j} (y_j^{(t)} - y_j) \quad (3.2)$$

Burada, $net_j = \sum x_i w_{ji}$ ve $y_j(t)$ ise j işlemci elemanının hedef çıkışıdır. Ara katlardaki nöronlar için ise bu faktör,

$$\delta_j = \left(\frac{\partial f}{\partial \text{net}_j} \right) \sum w_{jq} \delta_q \quad (3.3)$$

olarak verilir. Ara katlardaki nöronlar için herhangi bir hedef çıkış olmadığından, eşitlik (3.2) yerine eşitlik (3.3) kullanılır. Bu duruma bağlı olarak çıkış katından başlayarak δ_j faktörü, bütün katlardaki nöronlar için hesaplanır. Daha sonra eşitlik (3.1)'deki formüle bağlı olarak, bütün bağlantılar için ağırlıkların güncelleştirilmesi gerçekleştirilir (Rumelhart et al., 1986).

Başarılı ve hızlı bir eğitim süreci için, η ve α değerlerinin seçimi önemlidir. Geri yayılım öğrenme işlemi bu iki katsayıdan fazlaca etkilenmektedir. Bu katsayılar için uygun değerlerin seçilmesi deneysel olarak belirlense de bu değerler uygulamalara ve problemlere bağlıdır. Öğrenme katsayısı için tipik değerler 0,01 ile 0,9 arasında değişir. Karmaşık ve zor çalışmalar için daha küçük değerlerin seçilmesi önerilir (Sağıroğlu ve ark.,2003).



Şekil 3.11. ÇKA'nın geri yayılım akış şeması (Sağıroğlu ve ark.,2003)

3.3.9. ÇKA Ağının Çalışma Prosedürü

ÇKA ağlarının çalışması şu adımları içermektedir (Haykin, 1999):

1. *Ağırlıkların başlangıç değerlerinin atanması:* Proses elemanlarını birbirine bağlayan ağırlık değerlerinin ve eşik değer ünitesinin ağırlıklarının başlangıç değerlerinin atanması yapılır. Başlangıçta genellikle rasgele değerler atanır. Daha sonra ağ uygun değerleri öğrenme sırasında kendisi belirler.
2. *Öğrenme setinden örneklerin seçilmesi ve ağa gösterilmesi:* Ağın öğrenmeye başlaması ve öğrenme kuralına uygun olarak ağırlıkları değiştirmesi için ağa örnekler (girdi-çıkı değerleri) belirli bir düzeneğe göre gösterilir.
3. *Öğrenme sırasında ileri hesaplamaların yapılması:* l katmanındaki j nöronuna ait yerel hata ($v_j^{(l)}(n)$) şu formül ile hesaplanır:

$$v_j^{(l)}(n) = \sum_{i=0}^{m_0} w_{ji}^{(l)}(n) y_i^{(l-1)}(n) \quad (3.4)$$

$y_i^{(l-1)}(n)$ n.iterasyonda, (l-1) katmanındaki i nöronunun çıkışını; $w_{ji}^{(l)}(n)$, l katmanındaki j nöronunun ağırlığını belirtmektedir.

Sigmoid fonksiyonu kullanıldığı kabul edildiğinde, l katmanındaki j nöronunun çıktısı :

$$y_j^{(l)} = \varphi_j(v_j(n)) \quad (3.5)$$

şeklinde hesaplanır.

Eğer j nöronu çıktı katmanında ise, o halde denklem:

$y_j = o_j(n)$ haline dönuşür.

Bu durumda hata sinyali

$$e_j(n) = d_j(n) - o_j(n) \quad (3.6)$$

formülü ile hesaplanır. Burada $d_j(n)$ ifadesi beklenen çıktıyı temsil etmektedir.

4. *Geri hesaplamaların yapılması:* Ağın yerel gradienti (δ) aşağıdaki denklemler ile hesaplanır:

$$\begin{aligned} \delta_j^{(l)}(n) &= e_j^{(l)}(n) \phi_j'(v_j^{(l)}(n)) && \text{L çıktı katmanındaki j nöronu için} \\ \delta_j^{(l)}(n) &= \phi_j'(v_j^{(l)}(n)) \sum_k \delta_k^{(l+1)}(n) w_{kj}^{(l+1)}(n) && \text{l gizli katmanındaki j nöronu için} \end{aligned} \quad (3.7)$$

l katmanındaki ağırlıkların ayarlanması genelleştirilmiş delta kuralına göre yapılmaktadır:

$$w_{ji}^{(l)}(n+1) = w_{ji}^{(l)}(n) + \alpha[w_{ji}^{(l)}(n-1)] + \eta \delta_j^{(l)}(n) y_i^{(l-1)}(n) \quad (3.8)$$

yukarıdaki denklemde η öğrenme oranını, α ise momentum katsayısını göstermektedir.

5. *İterasyon:* 3. ve 4. adımlar ağ için eğitim seti durdurma kriterine ulaşınca kadar sürdürülür.

3.3.10. YSA Tasarımında Dikkat Edilmesi Gereken Konular

3.3.10.1. Uygulama Başarısı

YSA'larla çözümlenemeyecek problem sayısı çok azdır. Bunun başarılabilmesi için ise YSA uygulamalarında uygun metodolojiyi belirleme çok önem taşır. Uygulamaların başarısı bu metodolojinin en iyi bir şekilde belirlenmesiyle artacaktır. Başarılı bir tasarımda uygun olan yapıyı seçme, bu yapıya uygun öğrenme algoritmasını ve uygulanan algoritmanın uygun parametrelerini seçme, seçilen yapıya uygun giriş, ara katman ve çıkış sayılarını belirleme, ara katman nöron sayılarını yeteri kadar seçme, seçilen nöronlarda kullanılacak aktivasyon fonksiyonunu belirleme, eğitim ve test setleri ve bu setlerde kullanılacak olan normalizasyon seviyelerini belirleme gerçekten zor ve zaman alıcıdır (Öztemel, 2003).

Bir YSA'nın en uygun parametrelerle tasarlanması durumunda YSA sürekli olarak kararlı veya istikrarlı sonuçlar üretebilecek ve bu sayede güçlü (robust) bir sistem tasarımı gerçekleştirilebilecektir. Ayrıca sistemin tepki süresinin yeterince kısa olabilmesi içinde ağ büyüklüğünün yeterince küçük olması gerekir (Elmas, 2003).

3.3.10.2. Uygulamada Karşılaşılan Güçlükler

YSA'larda uygulama başarısı uygun parametrelerin seçimine bağlıdır. Uygun parametrelerin seçimi ise kolaylıkla yapılamamaktadır. Uygun parametrelerin seçiminde karşılaşılan bir çok güçlükler vardır (Sağıroğlu ve ark., 2003). Bunlar:

- Probleme uygun olan YSA yapısı seçimi
- Problemin kabul edilebilir çözümü için YSA giriş ve çıkış sayılarının en uygun sayıda seçimi
- Ara katman nöron sayılarının belirlenmesi

- Ara katman sayısının seçimi
- Kullanılacak öğrenme algoritmasının YSA yapısına uygun olması
- En uygun öğrenme algoritması parametrelerinin seçimi
- Seçilen veri kodlama yapısı
- Seçilen transfer fonksiyonun yapısı:
- Toplama fonksiyonu tipi:
- Uygun performans fonksiyonu seçimi
- Uygun iterasyon veya epoch sayısı seçimi
- Ön işleme ve son işleme (pre and post processing) işlemleri
- Uygun veri tipinin ve sayısının belirlenmesi
- Ağ yapılandırması

3.3.10.3. Uygulamada Takip Edilmesi Gereken İşlemler

Uygulamada dikkat edilmesi gereken en önemli unsurlar ile yapılması gerekenler şu şekilde sıralanabilir (Hornik, 1989; Masters, 1993; Sontag, 1991; Geman, 1992; Derks, 1995).

- *YSA Yapısı Seçimi:* Uygun YSA mimarisi veya yapısı uygulanan probleme bağlı olarak seçilmelidir. Bunun için YSA yapılarının hangi tip uygulama problemlerinde başarılı olacağının önceden bilinmesi faydalı olacaktır.
- *YSA Öğrenme Algoritması Seçimi:* Bir YSA yapısının seçiminden sonra uygulama başarısını belirleyen en önemli faktör ise öğrenme algoritmasıdır.

Seçilen YSA yapısı için en uygun öğrenme algoritmasının seçimi ağ yapısının seçiminden sonra çözülmesi gereken en önemli problemdir. Genellikle ağ yapısı öğrenme algoritmasının seçiminde belirleyicidir. Bu nedenle seçilen ağ yapısı üzerinde kullanılabilecek öğrenme algoritmasının seçimi çoğunlukla ağ mimarisine de bağlıdır.

- *Aktivasyon Fonksiyonunun Seçimi:* YSA'lara doğrusal olmama özelliği kazandıran ve bu sayede bir çok farklı probleme uygulama yaklaşımı sunması YSA'ların diğer bir üstünlüğüdür. Bu sayede bir çok problemin çözümüne uygulanabilmektedir. Problemin davranışına uygun olan fonksiyon tipinin belirlenmesi başarı yüzdesini yükseltebilir.
- *Ön ve Son Veri İşleme:* YSA'ların en belirgin özelliklerinden olan doğrusal olmama özelliğini anlamlı kılan yaklaşım, verilerin bir normalizasyona tabi tutulmasıdır. Verilerin normalizasyonu için seçilen yöntem YSA performansını doğrudan etkileyecektir. Çünkü normalizasyon, giriş verilerinin transfer edilirken fonksiyonun aktif olan bölgesinden aktarılmasını sağlar. Veri normalizasyonu, işlemci elemanlarını verilen kümülatif toplamlarla koruma eğilimleri nedeniyle zorunludur ve aşırı değerlendirilmiş kümülatif toplamların oluşturacağı olumsuzlukların engellenmesini sağlar. Genellikle verinin $[0,1]$ veya $[-1,+1]$ aralıklarından birine ölçeklenmesi önerilmektedir. Ölçekleme verinin geçerli eksen sisteminde sıkıştırılması anlamı taşıdığından veri kalitesi aşırı salınımlar içeren problemlerin YSA modellerini olumsuz etkileyebilir. Bu olumsuzluk, kullanılacak öğrenme fonksiyonunu da başarısız kılabilir.

Ön veri işleme (pre-processing) ve son veri işleme (post-processing) aşamaları dinamik yapıya sahip olan YSA uygulamalarında son derece önemli süreçlerdir.

Öncül veri işleme aşaması, verinin en doğru, en kısa ve en hızlı şekilde işlenmesi için hazırlanmasını ifade eder. Öncül işlemler sırasında çeşitli veri geliştirme araçlarından (interpolantlar, dönüştürücüler, kodlama algoritmaları) faydalanabilir. Öncül veri işleme aşamasında veri içerisinde

olası gürültü (noise) işaretlerinin bastırılması olanaklarından yararlanılmalıdır.

Son veri işleme aşaması, YSA çıkışının ne anlama geldiğinin yorumlandığı ve bu yorumun bilgiye veya başlangıç aşamasındaki veri tipine dönüştürüldüğü bir süreçtir. Ön ve son veri işleme aşamaları, uygulamaya bağımlı metotlar kullanmayı gerektirir.

- *Ara Katman ve/veya Ara Katman Nöron Sayısını Belirleme:* Literatürde, her türlü problemde maksimum iki ara katman kullanılması gerektiği ile ilgili ispatlar bulunmaktadır. Özel problemler için bu yaklaşım her zaman doğru olmayabilir. Bunun yanında, bazı özel problemlerin çözümünde bazı işlemci elemanlar arasında kompleks bağlantılara ihtiyaç duyulabilir. Bu durumlarda sadece en uygun sayıdaki işlemci eleman sayısını aramak veya elde etmek yeterli olmayabilir. Ayrıca en uygun bağlantı sayısı ve yapısını da bilmek faydalı olacaktır. Bir YSA tasarımı temel amaç YSA sisteminin mümkün olduğunca yalın veya basit bir yapıda tasarlanmasına dikkat etmektir. Bu karmaşıklığın artması öğrenme sürecini doğrudan arttırmakta ve yapının performansını olumsuz yönde etkileyebilmektedir.
- *Performans Fonksiyonu Seçimi:* Öğrenme performansını etkileyen önemli hususlardan birisi de performans fonksiyonudur. İleri beslemeli ağlarda kullanılan tipik performans fonksiyonu karesel ortalama hata (MSEP: mean squared error of prediction):

$$\text{MSEP} = \frac{\text{PRESS}}{n} = \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{n} = \frac{\sum_{i=1}^n e_i^2}{n}$$

ile ifade edilir. İleri beslemeli ağlarda kullanılan tipik performans fonksiyonlarından bir diğeri de karesel ortalama hata karekökü (RMSP: root mean squared error of prediction) olup:

$$RMSEP = \sqrt{MSEP} = \sqrt{\frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{n}} = \sqrt{\frac{\sum_{i=1}^n e_i^2}{n}}$$

formülü ile hesaplanır.

Performans fonksiyonuna ağırlık biasların ve ağırlıkların kareleri toplamının ortalama değerin ifade eden bir terim eklenerek genelleştirme iyileştirilebilir. Bu ağı daha hassas davranmaya zorlar ve ağı öğrenme kümesi haricindeki veriler içinde sağlıklı bir genelleme yapmasını engelleyebilir (overfitting).

Genelleştirmeyi iyileştirmek için kullanılan yöntemlerden birisi de öğrenmeyi erken sonlandırma (early stopping) işlemidir. Bu yöntemde kullanılabilir veri kümesi üç bölüme ayrılır. İlk küme YSA nesnesinin eğitiminde kullanılarak ağırlıkların, biasların ve gradientin güncelleştirilmesinde kullanılır. İkinci alt küme bir onaylama verisi olarak kullanılır.

Eğitim süresince test veri kümesine ait hata normal olarak düşer. Aynı düşüş, eğitim verilerinden hesaplanan hata miktarında da görülür. Bununla birlikte YSA eğitim verisi üzerinde bir aşırı öğrenme (overfitting) eğilimine girerse, onaylama veri kümesinden hesaplanan hata değeri artmaya başlar. Onaylama veri kümesinden hesaplanan hata değeri belirlenmiş bir değeri aşarsa, eğitim durdurularak ağırlık ve biaslar onaylama veri kümesinden elde edilen hataların minimum olduğu andaki değerlerine geri döndürülürler.

Test kümesinin hata değeri eğitim süresince kullanılmaz. Fakat bu hata değeri farklı modellerin kıyaslanması için faydalı olabilir.

Test kümesi hatasının eğitim süresince hesaplanması ve bu hatanın grafik çizimi bazı durumlarda oldukça kullanışlıdır. Eğer test veri kümesinden hesaplanan hata değeri, onaylama veri kümesinden hesaplanan hatadan tamamen farklı bir iterasyon sayısında minimum bir değere ulaşıyorsa bu veri

kümesinin bölünerek gruplandırılmasında sağlıklı bir yöntem izlenmediğini gösterir.

Öğrenme sürecini erken sona erdirme (early stopping) işlemi sonucunda elde edilen yakınsama, genellikle düzenlileştirme yaklaşımından biraz daha zayıf olmakla birlikte sonuç aşırı öğrenme (overfitting) sürecinden uzaklaşmıştır. Bu erken sonlandırma işleminin klasik bir özelliğidir.



4. ETKİN PİYASA HİPOTEZİ

4.1. Tanım

Belirli bir firma hakkında yeni bilgi ortaya çıktığında, piyasa iştirakçileri bu bilgiyi hangi hızla elde ederler veya bu bilginin ışığında menkul varlıklarını hangi hızla alırlar veya satarlar? Menkul kıymetlerin fiyatları yeni bilgiyi yansıtacak şekilde hangi hızla ayarlanır? Etkin Piyasa Hipotezi (EPH) bu gibi sorulara cevap aramak üzere ortaya atılmıştır. Hipoteze göre, fiyatlar yeni bilgilere hızlı bir şekilde tepki veriyorsa o piyasanın nispeten etkin olduğu söylenebilir. Aksine, bilgiler piyasada daha yavaş bir şekilde yayılıyorsa ve yatırımcıların bilgileri analiz etmesi veya tepki göstermeleri zaman alıyorsa, fiyatlar mevcut ilgili tüm bilgilerin dikkatli bir şekilde analizine dayanan değerlerden sapma gösterebileceklerdir. Bu tür piyasa nispeten etkin olmayan bir piyasa olarak isimlendirilebilir (Haugen, 2001).

‘Etkin Piyasa’ terimi ilk olarak 1961 yılında Fama tarafından ‘piyasanın yeni bilgilere hızlı uyumu’ şeklinde tanımlanmıştır. Bu tanım daha sonra yine Fama tarafından ‘varlık fiyatlarının etkin piyasada mevcut tüm bilgileri yansıtması’ şeklinde genişletilmiştir (Fama, 1991).

Jensen (1978), piyasa etkinliğini şu şekilde tanımlamıştır:

‘Bilgi seti temelinde ekonomik kar elde etmek mümkün değil ise piyasanın etkin olduğundan bahsedilebilir.’

Piyasa etkinliği için benzer bir tanım Malkiel (1992) tarafından yapılmıştır:

‘Sermaye piyasası, eğer hisse fiyatlarına karar vermede her bilgiye doğru ve tam tepki veriyorsa etkindir. Piyasanın etkin olması, tüm iştirakçilere açıklanan bilgi sonucunda hisse fiyatlarının etkilenmemesi şeklinde açıklanabilir. Buna ek olarak, bilgi setine tepki sonucunda oluşan etkinlik bu bilgi seti temelinde ekonomik kar elde etmeyi imkansızlaştırır.’

Fama'nın yaptığı deneysel çalışmalarda, firmaların kar payı politikalarındaki değişme, birleşmeler v.b. konularda, piyasada belirli bir fiyat ayarlama kalıbının olduğu tespit edilmiştir. Etkin Piyasa Hipotezinin mantıksal olarak doğru kabul edilebilmesi, bilgilerin hiçbir maliyete katlanmadan elde edilebilmesine bağlıdır. Ancak gerçek dünyada bilgiyi elde etmenin bir maliyeti olduğundan, ekonomik açıdan bakıldığında, yatırımcılar, bilgiyi elde etmenin marjinal kazancının marjinal maliyetini aştığı durumda bilgiye dayalı olarak tepki verebileceklerdir (Beechey et al., 2000). Bu sebeple etkinliği araştırılan bir piyasa, bazı bilgilerin fiyatlara yansımaları konusunda etkinken diğer bilgilerin yansıtılması konusunda etkin olmayabilir. Bu yüzden 'bu piyasa etkindir' veya 'bu piyasa etkin değildir' ifadeleri çok katı ve eksik yargılardır (Beaver, 1998).

Fama'nın Etkin Piyasalar Hipotezi ile ilgili varsayımları şu şekildedir (Cootner, 1962):

- Piyasada çok sayıda alıcı ve satıcı bulunmaktadır. Tam rekabet koşulları altında çalışan bir piyasada, hiçbir alıcı ve satıcı piyasayı etkileyecek güce ve paya sahip değildir.
- Her türlü bilgi herhangi bir eylem olmaksızın ve maliyet içermeksizin tüm yatırımcılara aynı anda ulaşabilmektedir.
- Elde edilen bilgiler tüm yatırımcılar tarafından aynı şekilde yorumlanmaktadır.
- Piyasalarla ilgili düzenlemeler piyasanın istikrarını sağlayacak şekilde geliştirilmiştir.
- İşlem maliyeti ve komisyon maliyeti olmamalıdır. Bu tür maliyetler piyasanın etkin işleyişini bozacaktır.

Etkin Piyasa Hipotezi (EPH) literatüründe Roberts (1967) ve Fama (1970) bilginin üç farklı formu olduğunu belirtmişlerdir:

Eğer bilgi seti sadece geçmişteki ve şu anki hisse fiyatlarını (kar payları veya değişim hacimleri gibi değişkenlerde olabilir) kapsıyor ise bilgi setinin ‘zayıf’ olduğu söylenebilir.

Geçmişteki verilerin yanı sıra kamunun ulaşabileceği genel bilgileri de içeren bilgi seti ‘yarı-güçlü’ olarak adlandırılmıştır.

Son olarak da diğer formlardaki bilgilere ek olarak özel bilgileri de içeren bilgi seti ‘güçlü’ olarak tanımlanmıştır.


Etkin Piyasa Hipotezini test eden pek çok çalışma zayıf yada yarı-güçlü bilgi seti formunu kullanmıştır.

Piyasalara her yeni gün, genel ekonomik durumla, grevlerle, ürün talebiyle, şirketlerin aldıkları finansal kararlarla v.b. konularla ilgili yeni bilgiler gelir. Doğal olarak bu bilgiler hisse senetlerinin fiyatlarını da etkilerler. Eğer piyasa etkinse, hisse senetleri fiyatlarının bu bilgileri alır almaz tepki göstermeleri gerekir. Doğal olarak bu tepki eş zamanlı olmayacaktır. Fakat bilginin alınması ve fiyatların tepkisi arasında geçen zaman boşluğu, bilgiyi alma ve değerlendirme teknik ve prosedürünün göstergesi olacaktır (Güngör, 2003).

4.2. Rassal Yürüyüşler Hipotezi (Random Walks Hypothesis)

Rassal Yürüyüşler Hipotezi, zayıf formda piyasa etkinliğinin incelenmesi sırasında ortaya atılmış ve ardışık fiyat hareketlerinin birbirinden bağımsız olduğunu ifade eden bir hipotezdir. Hipotezin doğruluğu, fiyat öngörülerıyla ilgili kurulacak rasyonel beklenti modelleri ve piyasa etkinliği konusunda yapılan araştırmalarda büyük önem taşımaktadır (Güngör, 2003).

Rassal yürüyüş ve zayıf piyasa hipotezleri, Fama (1965)’nin günlük bazda fiyat korelasyonunu kullanarak, günlük fiyat değişimleri arasında önemli bir ilişkinin olmadığını iddia ettiği çalışmasıyla ortaya çıkmışlardır. Fama, bu çalışmasında 1958-



1962 yıllarını kapsayan Dow Jones Endüstriyel Ortalama'daki hisse senetlerinin günlük fiyat değişimleri arasındaki ilişkiyi incelemiş ve önemli bir korelasyon bulamadığı için, günlük fiyatlar arasındaki bağımlılığın, yatırım teorisi ve istatistiksel bakımdan değer taşımadığını ifade etmiştir (Pettengill, 1989).

Rassal Yürüyüşler Hipotezinin aksini savunan görüşler de mevcuttur. Bunlardan ilki menkul kıymet getirilerinde rassal olmayan mevsimsel kalıpların olduğunu savunan görüştür. Bu görüşe göre, menkul kıymet borsalarında günlere, aylara ve tatillere ilişkin bir takım anomaliler (anomali:kural dışı olan şey, Redhouse, 1995) vardır ve bu anomaliler hisse senedi getirileri arasındaki korelasyonu güçlendirmektedir.

Günlere ilişkin anomalilerde, haftanın belirli bir gün veya birkaç gününde, diğer günlere kıyasla sürekli düşük veya yüksek getiri elde edilip edilemeyeceği araştırılmaktadır. Bu anomalilerin en çok bilineni pazartesi etkisidir. Bu etki, hisse senedi getirilerinin haftanın ilk işlem günü olan pazartesi gününde sistematik olarak negatif getiri sağlamaları şeklinde ifade edilmektedir (Özmen, 1997). Farklı ülkelerde yapılan bir çok araştırmada bu etkinin varlığı kabul edilmiştir.

Günlere ilişkin anomalileri konu alan çalışmalarda başlıca iki görüş hakimdir. Bunlardan birisi, günler ilerledikçe yatırımcıların iyimserlik düzeylerinin artacağını ve dolayısıyla haftanın son işlem günü olan Cuma gününde en yüksek getirinin sağlandığını savunan 'mavi pazartesi' hipotezidir. İkinci hakim görüş ise, günlük anomalilere ilişkin 'ilan etkisi' dir. İlan etkisi hipotezine göre, firmalar yapmayı düşündükleri ilanların (kar, kar payı v.b.) zamanlamasını bu ilanların hisse senedi fiyatlarına etkisini yumuşatacak şekilde seçerler. Buna göre firmayla ilgili kötü haberler ilişkin ilanlar genellikle hafta sonunda yatırımcıların tepkilerinin soğuması amacıyla Cuma günü geç saatlerde yapılır. Bu sebeple fiyat düşüşleri genelde pazartesi gününe rastlar (Pettengill and Buster, 1994).

Aylık anomalilere ilişkin çalışmalar, menkul kıymet getirilerinin yılın herhangi bir ayında diğer aylara kıyasla getiri farklılığının olup olmadığını incelemektedir. Bu anomalileri en çok bilineni Ocak etkisidir. İlk olarak Wachtel (1942) tarafından ortaya konan Ocak ayı etkisine göre, menkul kıymetler yılın diğer aylarına kıyasla

Ocak ayında daha yüksek getiri sağlamaktadır. 1976'da Rozeff ve Kinney tarafından yapılan ve New York Borsasının 1904-1974 yıllarını kapsayan çalışmada ise Ocak ayının diğer aylara göre en yüksek getiriyi sağladığını, bu ayın ortalama getirisinin %3,5 iken diğer ayların yalnızca %0,5 olduğunu ve yıllık getirilerin yaklaşık olarak 2/3'sinin Ocak ayında elde edildiği ifade edilmektedir (Özmen, 1997).

Menkul kıymet borsalarında ortaya çıkan bir diğer anomali tatillere ilişkin anomalidir. Tatil etkiler konusunda ilk çalışma Fields (1934) tarafından yapılmıştır. Sonradan Roll (1983) Lakonishok ve Smidt (1984), Aralık ayının son günü ile Christmas tatili öncesi hisse senetleri getirilerinin olağandışı bir şekilde yükseldiğini tespit etmişlerdir. Rogalski (1984), resmi tatil sonrası getirilerle normal tatillerden (hafta sonları) sonraki getiriler arasında önemli farklılıklar bulmuş ve bunun sebebinin haftanın günleri ve firma büyüklüklerinden kaynaklandığını belirtmiştir. Pettengill ve Jordan (1988) ise, küçük firmalar için tatil öncesi getirilerin, büyük firmalar için ise tatil sonrası getirilerin önemli olduğunu ve tatil sonrası getirilerin haftanın belirli bir gününe bağlı olmaksızın oldukça yüksek gerçekleştiğini belirtmişlerdir (Güngör, 2003).

Rassal Yürüyüşler Hipotezini savunanların bir dayanağı, hisse senedi fiyatlarının geçmişteki tüm bilgileri yansıtmaları ve yalnızca yeni bir bilginin ortaya çıkmasıyla değişmesidir. Gelecekte ortaya çıkacak bilgiler, geçmiştekenden bağımsız olacağına göre ardışık fiyat değişimleri birbirinden bağımsız olacaklardır. Hissedarlar hiçbir zaman gelecekte ortaya çıkacak bilgilerin iyi yada kötü olacağını önceden kestiremezler.

4.3. Etkin Piyasa Hipotezine Karşı Ortaya Konan Anomaliler

4.3.1. Aşırı Tepki Hipotezi (Overreaction Hypothesis)

Etkin Piyasalar Hipotezine karşı ortaya atılan en önemli anomalilerden birisi, yatırımcıların piyasaya ortaya çıkan haberler karşı verdikleri aşırı veya zayıf tepkidir.

Aşırı tepki hipotezi De Bondt ve Thaler (1985) tarafından ortaya atılmıştır. Söz konusu hipotez, yatırımcıların hisse senedi fiyatlarını elde ettikleri yeni bilgiler çerçevesinde değerlendirirken, firmanın nakit akım veya kazanma güçleri ile ilgili beklentilerinde büyük bir değişme ortaya koyan çok iyi yada çok kötü haberlere aşırı tepki vermekte oldukları ve bu aşırı tepkiyi 3-5 yıl gibi çok uzun bir zamanda düzelttiklerini ifade etmektedir.

De Bondt ve Thaler'den sonra da, bu konuyla ilgili bazı çalışmalar yapılmış ve benzer sonuçlar bulunmuştur. Yatırımcıların ilan zamanında aşırı tepki vererek hisse senedi fiyatlarını aşırı derecede düşürdükleri veya yükselttikleri, ardından da zaman içinde bu durumun farkına vararak, hisse senetlerini gerçek değerlerine çekmek için düzenleme yapmaları bakımından bu etki piyasa etkinliği açısından bir anormallik olarak kabul edilmekte ve Aşırı Tepki Hipotezi olarak adlandırılmaktadır (Özer, 2000).

Howe (1986) tarafından yapılan çalışmada iyi ve kötü haberli şeklinde sınıflandırılan hisse senetlerinin 50 haftalık getirileri incelenmiş ve aşırı tepki hipotezini destekleyen bulgular elde edilmiştir.

Bloomfield, Libby ve Nelson (2000), aşırı ve zayıf tepki hipotezini zayıf formda etkinlik ve yarı-güçlü formda etkinlik açısından ele almışlar ve aynı veri setini kullanarak yaptıkları çalışmada, geçmişteki tüm bilgilerin, hisse senedi fiyatlarına yansıtıldığı zayıf formda etkin piyasalarda aşırı tepki gözlenirken, kamuya açıklanan tüm bilgilerin fiyatlara yansıtıldığı yarı-güçlü piyasalarda zayıf tepkinin ortaya çıktığını ifade etmişlerdir.

Aşırı ve zayıf tepkinin ortaya çıkmasında psikolojik faktörleri göz önünde bulunduran Kahneman ve Tversky (1990), insanların çok iyi yada çok kötü haberler olması gerekenden daha fazla daha zayıf tepkiler verdiğini ve belirsizlik koşullarında karar verme durumunda olan insanların, doğru karar verme normlarından sapabileceklerini ifade etmektedirler. Kahneman ve Lavallo (1993)'nun yaptıkları çalışmada ise, karar vericilerin kararın sonrasında ortaya çıkacak sonuçları tahmin etmede, kendilerine aşırı güven duydukları ve bunun hatalı sonuçlara yol açtığı belirtilmektedir.

Bu konuda yapılan en detaylı araştırmalardan biri Griffin ve Tversky (1992)'nin çalışmasıdır. Yazarlar çalışmalarında, bilgiyi güçlerine ve ağırlığına göre iki gruba ayırmışlardır. Bilginin gücü, haberin lehte veya aleyhte (olumlu yada olumsuz) olmasıyla ifade edilirken, bilginin ağırlığı ise istatistiksel açıdan güvenilebilirliği şeklinde ifade edilmektedir. Çalışmada, insanların bilginin gücüne aşırı derecede önem verirken, bilginin ağırlığına yeteri derecede önem vermedikleri konusunda kanıtlar sunulmaktadır. Bunun bir sonucu olarak, bilginin gücünün oldukça yüksek ve ağırlığının düşük olması durumunda aşırı tepki ortaya çıkarken, bilgi gücünün düşük fakat ağırlığının yüksek olması durumunda ise düşük (zayıf) tepki ortaya çıkmaktadır.

Bu konuda Bloomfield, Libby ve Nelson'un (1998) yaptıkları başka bir çalışmada gerek ilan sonrası sapmaların, gerekse aşırı tepkilerin yatırımcıların önceki döneme ait kar rakamlarına aşırı derecede güvenmelerinden kaynaklandığını belirtmektedir. Yazarlar, önceki döneme ait kar rakamlarına aşırı güvenin bu iki piyasa anomalisini ortaya çıkarmasının sebebini, gelecekteki karları tahmin etmede cari kar rakamları yerine önceki kar rakamlarının kullanılmasının güvenilir olmadığı ve bireylerin güvenilir olmayan bilgilere aşırı derecede itimat etmeleri şeklinde açıklanmaktadır.

Aşırı Tepki Hipotezi konusunda elde edilen sonuçların, Etkin Piyasa Hipotezi ile önemli derecede zıtlıklar gösterdiği görülmektedir. Etkin piyasalar, piyasadaki mevcut tüm bilgilerin hisse senedi fiyatlarına yansıtıldığı ve fiyatların yeni bilgilere karşı anında tepki verebildiği piyasaları ifade etmektedir. Ancak eğer bir piyasada, Etkin Piyasalar Hipotezinde varsayıldığı gibi yeni bilgiler anında tüm yatırımcılara yayılamıyorsa yada bu bilgileri elde etmenin önemli düzeyde maliyeti varsa bilgilerin fiyatlara geç yansıması mantıklı görülmektedir. Aşırı Tepki Hipotezinde dikkat çeken bir diğer konu ise Jegadeesh ve Titman'ın (1993) çalışmasında bahsedildiği gibi dolaylı olarak da olsa önceki dönemlerde gerçekleşen hisse senedi getirilerinin, sonraki dönemlerdeki getirilerin tahmininde kullanılabileceği düşüncesidir.

Etkin Piyasa Hipotezini ortaya atan Fama (1998), piyasalarda gerçekleştiği söylenen aşırı tepki veya zayıf tepkinin bu hipotezi asla ortadan kaldırmayacağını

savunmaktadır. Etkin piyasalarda, aşırı tepkiler kadar zayıf tepkilerin de görülebileceğini ileri süren yazar, anomalilerin zayıf ve aşırı tepki arasında rassal olarak dağılmasının hipotezle bağdaşacağını ifade etmektedir. Yazar, çalışmasında ayrıca aşırı tepki veya zayıf tepkinin hisse senedi fiyatlarının yavaş bir şekilde bilgilere göre ayarlandığının göstergesi olabileceğini belirtmektedir.

4.3.2. Kazancın Zamanlılığı (Timeliness of Earnings)

Etkin Piyasalar Hipotezine karşı ortaya atılan bir diğer anomali ise, kazancın zamanlılığıdır. Bu konu ilk olarak Ball ve Brown (1968) tarafından gündeme getirilmiştir. Yazarlar, yaptıkları çalışmada, yıllık kazanç ilanlarını ele almışlar ve kazanç ilanlarıyla ilgili fiyat tepkilerinin çoğunun ilandan önce gerçekleştiğini tespit etmişlerdir.

Ball ve Brown'un bu tespitleri aslında şaşırtıcı değildir. Çünkü, yıl boyunca yatırımcıların yıllık kazançlar hakkında tahmin yapmalarına imkan veren birçok bilgi piyasaya aktarılmaktadır. Bu bilgilere örnek olarak, üç aylık kazanç ve kazanç payı ilanları, analistlerin veya şirket yöneticilerinin yaptıkları tahminler verilebilir.

Morse (1981), günlük verileri kullanarak AMEX ve NYSE gibi organize olmuş borsalardaki firmalar üzerine bir araştırma yapmıştır. Morse'un çalışmasında en belirgin fiyat ve işlem hacmi değişimleri Wall Street Journal'daki açıklamaların yayınlandığı günden bir gün önce veya yayın gününde ortaya çıkmıştır. Yazar, kazanç ilanlarına gösterilen fiyat tepkilerini şu şekilde açıklamaktadır:

“Şayet sıfırdan farklı elemana sahip olan bireysel alt kümeler, inanışlarını değiştirecek sinyaller algılayarsa, ilanın yapıldığı tarihlerde belirgin fiyat değişimleri gözlenebilir. Bu sebeple, ilandan önceki fiyat değişimleri, bu ilanla ilgili bir işaretin toplumun bir alt kümesi tarafından önceden algılandığının bir göstergesidir. İlanlardan hemen sonraki fiyat değişimleri ise bir işaretin meydana getirdiği inanışlardaki uzlaşım değişimini ifade eder.”

Patell ve Wolfson (1984), yaptıkları çalışmada kazanç ilanlarına karşı fiyat tepkilerini gün ve saat bazında ölçmüşler, kazanç ilanının yapıldığı saatteki fiyat

değişimlerinin, ilan yapılmayan saatlerden beş kat daha fazla olduğunu tespit etmişlerdir. Çalışmada ayrıca, en büyük fiyat değişimlerinin ilandan sonraki iki saat içinde gerçekleştiği ve bu değişimin ilandan sonraki gün de devam ettiği vurgulanmaktadır. Yazarlara göre, yıllık ilandan önce elde edilen bilgiler fiyatlara yansıtılmış olsa da, yıllık kazanç ilanları ilan edildiği tarihte etkisini büyük ölçüde göstermektedir.

Yukarıda bahsedilen çalışmalardan elde edilen bulguların Ball ve Brown'un fikirleriyle çeliştiği görülmektedir. Bu çelişkinin sebebi, kazanç tahminlerinde, üç aylık kazanç ilanlarının yanında yönetici ve analistlerin yaptıkları kazanç tahminleri, dava ilanları ve yapılan kontratlar gibi bilgi içeriğine sahip diğer verilerin kullanılmasında yatmaktadır. Günümüzde, internet vasıtasıyla firmalar hakkında sürekli olarak piyasaya bilgi aktarıldığı göz önünde bulundurulması gerekir. Söz konusu verilerin, kazanç beklenti modellerinde etkin bir şekilde kullanılması için bunlarla ilgili değişikliklerin sürekli takip edilmesi ve modele katılması gerekir. Aksi halde kurulan beklenti modelleri hatalı tahminlere yol açacak ve firmanın gelecekteki kazanç potansiyeli hakkında yanlış yönlendirmelere sebep olacaktır.

4.3.3. Firma Büyüklüğü Anomalisi

Bu konuda daha önce yapılmış olan çalışmaların birçoğunda, küçük firmaların kazanç raporlarının büyük firmalara nispeten daha fazla fiyat etkisi ortaya çıkardığı iddia edilmektedir. Bu iddianın dayanağı ise, büyük firmalarla ilgili işlem karlarına yönelik bir çok araştırmanın yapılması ve dolayısıyla bu firmaların fiyatlarının daha fazla bilgi içermesine karşılık, küçük firmalara nispeten, kazanç ilanlarının daha az bilgi içermesidir (Güngör, 2003).

Firma hakkında bilgi elde etme konusunda yatırımcıların en önemli kriteri, bilginin sağlayacağı işlem karının bilgiyi elde etme maliyetinden yüksek olmasıdır. Marjinal işlem karının büyük firmalar için daha yüksek olduğu düşünüldüğünde, fiyatların bilgi içeriğinin büyük firmalar için daha fazla olduğu söylenebilir. Bilgi üretimi ve bu bilginin piyasaya yayılması, firma büyüklüğünün artan bir fonksiyonu olması sebebiyle, kazanç ilanları gibi, muhasebe verilerine dayanan raporların da

piyasaya taşıdıkları bilginin firma büyüklüğü ile ters ilişkili olduğu söylenmektedir (Han and Wild, 2000).

Firma büyüklüğünün hisse senedi verimi üzerine etkisi konusunda birçok çalışma yapılmıştır. Foster, Olsen ve Shelvin (1984)'in büyük ve küçük firmalar için standart beklenmeyen kazançlar ve kurdukları portföylere göre birikimli ortalama anormal verimleri karşılaştırdıkları çalışmalarında, en küçük firmaları kapsayan aralıktaki ortalama günlük verimin, en büyük firmaları kapsayan aralıktaki ortalama günlük verimden beş kat daha fazla olduğunu tespit etmişlerdir. Ataise (1985) yaptığı çalışmada, kazanç ilanlarıyla piyasaya taşınan 'beklenmeyen' bilgi miktarının firma büyüklüğü ile ters ilişkili olması gerektiğini savunmaktadır. Yazar yaptığı analizler sonucunda, kazanç ilanlarına karşı beklenmeyen fiyat değişimleriyle, firmanın büyüklüğü arasında ters bir ilişkinin varlığını tespit etmiştir.

Firma büyüklüğü ile kazanç ilanlarına karşı fiyat tepkisinin ters ilişkili olduğu iddiasına, Freeman (1987), büyük firmalarla ilgili yapılan bir çok araştırmanın olmasının yanında, büyük firmaların kar serilerinin küçük firmalara nispeten daha az dalgalanması ve daha kolay tahmin edilebilmesi şeklinde bir açıklama getirmektedir. Yazar, çalışmasında istatistiksel bulgularla desteklediği iki önemli sonuca ulaşmıştır. Birincisi, büyük firmaların hisse senedi fiyatlarının küçük firmalardan daha önce karları yansıttığı, ikincisi ise haberin içeriği ne olursa olsun (iyi yada kötü) anormal verimlerin firma değerleriyle ters ilişkili olduğudur.

Sonuç olarak, yapılan çalışmalarda ulaşılan genel yargı, küçük firmalara ait kazanç ilanlarının, büyük firmalara nazaran daha fazla anormal verimlere yol açtığıdır. Bu durumun ortaya çıkış sebebi ise, küçük firmalara ait bilgilerin büyük firmalara nispeten piyasaya daha geç yansması ve bu sebeple ilan zamanında daha fazla fiyat tepkisine yol açması, yapılacak araştırmaların maliyet-kar analizi açısından büyük firmalar için daha cazip olması, küçük firmaların riskinin fazla olması ve karlarının daha fazla dalgalanma göstermesi şeklinde ifade edilebilir.

4.4. Kazanç Bildirileri İçin Sınıflandırma Modeli

Bu çalışmadaki amacımız kazanç bildirilerini kısa dönem hisse/portföy yönetiminde nasıl kullanabileceğimizi araştırmaktır. Kısa dönem fiyat değişimleri pek çok araştırmacı tarafından araştırılmıştır. Onların bulguları, kazanç bildirisinden önce hisse fiyatlarının arttığı fakat bildiriden sonra negatif veya pozitif bir fiyat değişimi olmadığı yönündedir (Morse, 1983). Diğer taraftan, biz çalışmamızda kazanç bildirisinden sonraki beş gün içerisinde hisse fiyatlarının değişkenlik gösterdiğini bulduk. Bu değişikliğin kazanç sonuçlarına, hisse fiyatına ve olumlu ya da olumsuz kazanç sürprizlerine bağlı olduğunu gözlemledik.

Büyük firmalar için sermaye piyasasının küçük firmalara nazaran daha etkin olduğunu bir önceki bölümde belirtmiştik. Hisse değişkenliği, firmanın boyutu, kazanç sonuçları ve kazanç sonuçlarına bağlı olarak modellenenebilir.

Bu kabuller ışığı altında hisse senetleri için iki sınıf belirlenmiştir (1:satın al, 2:satın alma). ‘Satın al’ sınıfı, kazanç bildirisinden sonraki beş günlük getirinin %5’den büyük; ‘Satın alma’ sınıfı ise kazanç bildirisinden sonraki beş günlük getirinin %5’den küçük olması şeklinde tanımlanmıştır. Aşağıdaki değişkenler giriş değişkenleri olarak kullanılmıştır.

Hisse Başına Kazanç (Earning Per Share, EPS) : Her hisse için kazanç bildirisinden önceki son beş çeyrekteki hisse başına kazanç değerleri alınmıştır (EPS_{t-1} , EPS_{t-2} , EPS_{t-3} , EPS_{t-4} , EPS_{t-5}). Bu sayede, firmaların finansal gidişatları hakkında elde edilen bilgilerin piyasa iştirakçileri tarafından nasıl yorumlandığı araştırılmıştır.

Sürpriz : Sürpriz, her hisse için kazanç bildirisinden önceki iyi ya da kötü haberler olarak tanımlanmıştır. Eğer gerçek EPS’nin tahmin edilenden büyük olacağına ilişkin haberler varsa sürpriz değeri +1, tahmin edilen değer ile gerçek değer aynı olacağına ilişkin haber var ise 0, gerçek değer tahmin edilenden küçük olacağına ilişkin haber var ise -1 değeri alınmıştır.

Fiyat : Her hissenin fiyatı bir diğer önemli değişkendir. Her hisse için kazanç bildirisinden sonraki ilk işlem günündeki hisse fiyatı alınmıştır.

Sonuç olarak çıktı değerleri ile girdi değerleri arasında şu ilişkiyi elde edilmiştir:

t: bildiri tarihini göstermek üzere,

$$f(x) = (EPS_{t-1}, EPS_{t-2}, EPS_{t-3}, EPS_{t-4}, EPS_{t-5}, \text{Sürpriz}, \text{Fiyat})$$



5. ARAřTIRMA UYGULAMASI

5.1. Arařtırmanın Amacı

Bu alıřmanın amacı, gemiř dnemdeki kazanç bildirilerini, hisse fiyatlarını ve her hisse iin bildiri tarihinden nce aıklanan olumlu yada olumsuz haberleri kullanarak, bireysel yatırımcılara ve kurumlara hisse/portfy ynetiminde en iyi getiriyi saėlayacak matematiksel bir algoritma geliřtirmektir. Son yıllarda finans dnyasında kullanılmaya bařlanan ve Yapay Zeka iin bir ėrenme yntemi olan Yapay Sinir Aėları'nın hisse senedi gruplandırmasında kullanılarak, yatırımcıya kısa dnemde en iyi getirileri saėlayacak hisse seiminde yardımcı olması alıřmanın temel hedefidir.

5.2. Arařtırmanın Kapsamı

NASDAQ (National Association of Securities Dealers Automated Quotations), 8 řubat 1971 tarihinde elektronik ortamda hisse alıř-satıřı yapmak zere kurulmuř ABD'nin ve dnyanın ilk online borsasıdır. oėunluėu teknoloji, haberleřme, finans, ulařım, medya ve bio-teknoloji sektrlerinde faaliyet gsteren 4000'e yakın firma bu borsada iřlem grmektedir. NASDAQ, her gn online yatırımcılara, řirket bilgileri, kotalar ve dakikası dakikasına finansal haberler sunmaktadır (nasdaq.com).

alıřmamızda NASDAQ Index'inde iřlem gren 679 firmanın kazanç bildirisinden nceki son aıkladıkları beř kazanç bildirisi, her hissenin bildiriden sonraki ilk iřlem gnndeki fiyatı ve srpriz deėerleri alınmıřtır.

5.3. Deneysel Sonuçlar

5.3.1. Gruplandırma

Araştırmamızın ilk kısmı gruplandırmayı (kümeleme-clustering) kapsamaktadır. Kümeleme; gruplandırılmamış verileri benzerliklerine göre sınıflandırarak, araştırmacıya özet bilgi sunmaktır. Bir başka ifade ile n sayıdaki değişkeni kendi içinde aynı fakat kendi aralarında birbirlerinden farklı olacak şekilde gruplandırılmasıdır. Kümeleme analizi yapmakla araştırmacı, model uydurmanın daha basit bir hale getirilmesini, hipotez testini, veri yerine küme kavramının kullanılmasını ve aykırı değerlerin bulunmasını hedeflemektedir. Kümeleme yöntemleri hiyerarşik ve hiyerarşik olmayan kümeleme yöntemleri olarak ikiye ayrılabilir.

Hiyerarşik tekniklerden en yaygın olanları, tek bağlantı yöntemi (en yakın komşuluk) ve tam bağlantı yöntemi (en uzak komşuluk) şeklindedir.

Hiyerarşik olmayan kümeleme teknikleri; araştırmacı küme sayısına karar vermişse ancak o zaman uygulanabilir. Bunlardan da en yaygın olanı Mac Queen tarafından geliştirilen k ortalamalar (k -means) tekniğidir. Bu yöntem n sayıda birimin k kümeye ayrılmasında birimin p boyutlu uzayda gösterimi olan en yaygın ortalamaya sahip çekirdek noktalı bir kümeye atanmasını içerir. K ortalamalar tekniğinde en yüksek benzerliğe sahip olan birimlerin bir araya getirilmesi hedeflenmiştir (Özdamar, 1999).

Küme Sayısının Belirlenmesi : Küme sayısını belirlerken, k küme sayısını, n 'de gözlem sayısını göstermek üzere küme sayısını; $n/2$ 'nin karekökünün yaklaşık değerini alarak hesaplamak mümkündür. Fakat bu formül küçük örneklemeler için doğru sonuç verirken, büyük örneklemeler için doğru sonuç vermediği durumlarla da karşılaşmak mümkündür (Tatlídil, 2002).

Çalışmamızda her hissenin bildiriden sonraki ilk işlem günündeki fiyatı ve sonraki beş günde ortalama getirileri alınarak en yüksek getiri miktarının hangi fiyat

aralığında olduğu araştırılmıştır. Gruplandırma işleminde SPSS istatistik programı kullanılmıştır. Sınıflandırma modelimizde k-ortalama metodu seçilmiş ve $k=3$ alınmıştır. Bu sayede borsada işlem gören hisseler ve dolayısıyla firmalar küçük-orta-büyük şeklinde gruplandırılmıştır.

Fiyatlara göre ortalama getiriler ve satın al- satın alma sınıflarına ait olan hisse sayıları aşağıdaki tablolarda verilmiştir.

Tablo 5.1 Fiyat aralığı ve getirilerin tanıtımsal istatistikleri

	Fiyat Aralığı (\$)		
	s < 17	17 < s < 39,5	s > 39,5
Minimum Getiri	-0,55	-0,28	-0,15
Maksimum Getiri	0,62	0,36	0,17
Ortalama Getiri	0,067	0,024	0,021
Standart Sapma	0,123	0,076	0,056



Tablo 5.2 Her sınıftaki hisse sayıları

Fiyat Aralığı (\$)	Satın Al	Satın Alma	Toplam
s < 17	207	177	384
17 < s < 39,5	61	162	223
s > 39,5	13	59	72
Toplam	281	398	679

Tablo 5.1 de düşük fiyatlı hisse senetleri için standart sapma değerinin diğerlerine oranla daha yüksek olduğu görülmektedir. Bu istatistiksel bilgi küçük firmalara ait hisse senetlerinde daha yüksek risk olduğu ve bölüm 4.3.3 de anlatıldığı gibi ‘sermaye piyasasının küçük firmalar için daha az etkin olduğu’ kabulünü doğrulamaktadır. Ortalama getiriler göz önüne alındığında yine küçük firmalara ait hisse senetleri ile daha fazla kazanç elde edileceği görülmektedir. Tablo 5.2 küçük firmalara ait hisse senetleri için ‘satın al’ önerisinin diğer sınıflara nazaran daha fazla olduğunu belirtmektedir.

5.3.2. Yapay Sinir Ağı Uygulaması

Araştırmamızın ikinci aşaması hisse senedi seçiminin bilgisayar ortamında yapılmasını sağlayacak YSA nı meydana getirmektir. Çalışmamızda MatLab 6.5 programı kullanılmıştır. Girdiler olarak aşağıda verilen yedi değer kullanılmış, çıktı olarak ise ağın ‘satın al = 1’ veya ‘satın alma = 0’ değerlerinden birini vermesi istenmiştir.




Şekil 5.1. Yapay Sinir Ağının Topolojisi

Çalışmamızda kullandığımız Yapay Sinir Ağı için optimum verimi sağlayacak topolojiyi belirlemedeki en önemli sorun gizli katmanda bulunan nöron sayısının kaç olacağıdır. Literatürde bu konuda herhangi bir kural bulunmamakla birlikte bu sayı, eğitim ve test çalışmalarında her seferde farklı sayıda nöron sayısı girip elde edilen sonuçları yorumlamak suretiyle belirlenebilmektedir.

Tezimizde kullandığımız 679 veri setinin 600 ü ağıın eğitiminde, 79 u ise eğitilen ağıın test işleminde kullanılmıştır. Aktivasyon fonksiyonu olarak Logaritma Sigmoid fonksiyonu seçilmiştir.


Y_N : Gizli katmanında N adet nöron bulunan ağı ifade etmektedir. Her ağıın eğitim ve test süreçleri sonucunda sergilediği performansı gösteren grafik aşağıda verilmiştir.



Şekil 5.2. Gizli katman nöron sayısının değişiminin performans ile ilişkisi

Grafik incelendiğinde, nöron sayısı arttıkça eğitim için tahmin doğruluğunun arttığı, buna karşılık test setinin tahmininde hataların yükseldiği görülmektedir.

Yapay Sinir Ağı ile gruplandırma sürecinde kullanılan ve farklı sayıda gizli katman nöronuna sahip topolojilerin performansını belirlemede 'olasılık tablosu'ndan yararlanılır. Bu tablo sayesinde hesaplanan değerler, gözlemlenen ve tahmin edilen satın al-satın alma kararları arasındaki tutarlılığı ve dolayısıyla ağın performansını belirtir (Trafalis et al., 2000). Bu tablonun yapısı aşağıda gösterilmiştir.



Tablo 5.3. Olasılık Tablosu

		GÖZLEMLENEN		
		SATIN AL (+1)	SATIN ALMA (-1)	TOPLAM
TAHMİN	SATIN AL(+1)	İSABET (a)	YANLIŞ ALARM (b)	TAHMİN SATIN AL(a+b)
	SATIN ALMA(-1)	İSABETSİZLER (c)	DOĞRU NEGATİFLER (d)	TAHMİN SATIN ALMA(c+d)
TOPLAM		GÖZLENEN SATIN AL(a+c)	GÖZLENEN SATIN ALMA (b+d)	

Bu tablo yardımıyla hesaplanan değerlerin formülleri ve anlamları aşağıda verilmiştir.

Tahminin Doğruluğu (Probability of Detection, POD) : POD değeri doğru tahmin edilen gözlemleri belirtmektedir. Bu değerin yüksek olması ağın performansının iyi olduğunu gösterir.

$$POD = a / (a + c) \quad (5.1)$$

Yanlış Alarm Oranı (False Alarm Rate, FAR) : FAR, ‘satın al’ olarak tahmin edilen fakat gözlem sonucunda ‘satın alma’ grubuna dahil olduğu anlaşılan tahminlerin oranını vermektedir.

$$FAR = b / (a + b) \quad (5.2)$$

Kritik Başarı Endeksi (The Critical Success Index, CSI) : Bu oran 0 ile 1 arasında bir değer almakla birlikte, 1 kusursuz performansı ifade etmektedir.

$$CSI = a / (a + b + c) \quad (5.3)$$

Doğruluk (Accuracy, ACC) : ACC, doğru olarak tahmin edilen tüm gözlemlerin toplam gözlem sayısına oranıdır.

$$ACC = (a + d) / \text{toplam} \quad (5.4)$$

Bias : Bu değer tahmin edilen ‘satın al’ sayısının, gözlemlenen ‘satın al’ sayısına oranıdır. 0 dan 1’e kadar değer alabilir. Ağın iyi performansa sahip olduğunun söylenebilmesi için bu değer 1’e yakın olması istenir.

$$Bias = (a + b) / (a + c) \quad (5.5)$$

Yanlış Tahmin Olasılığı (Probability of False Detection, POFD) : ‘Yanlış alarm’ sayısının gözlemlenen ‘satın alma’ sayısına oranıdır. 0 dan 1 e kadar değer alır; 0 kusursuz performansı belirtmektedir.

$$POFD = b / (b + d) \quad (5.6)$$

H – K Yeteneği (H – K Skill) : Doğru tahmin etme olasılığı ile yanlış tahmin etme olasılığı arasındaki farktır. Bu değer 1 olması ağın yeteneğinin; 0 olması ise ağın yeteneksizliğinin en üst göstergeleridir.

$$H-K Skill = [a / (a + c)] - [b / (b + d)] \quad (5.7)$$

Odds Oranı (Odds Ratio, OR) : Doğru tahmin yapma olasılığının yanlış tahmin olasılıklarına oranı şeklinde ifade edilir. 0 dan sonsuza kadar değer alabilir. Bu oranın yüksekliği ağın performansının iyi olduğunu belirtir.

$$OR = (a * d) / (c * b) \quad (5.8)$$

Her ağ yapısı için olasılık tablosundaki değerleri içeren tablolar aşağıda verilmiştir.

Tablo 5.4. Eğitim seti için olasılık tablosu

	Y4	Y7	Y10	Y14	Y21	Y28	Y35
a	132	151	173	198	217	227	202
b	53	60	46	18	14	11	8
c	113	94	72	46	28	18	43
d	302	295	309	337	341	344	347

Tablo 5.5. Test seti için olasılık tablosu

	Y4	Y7	Y10	Y14	Y21	Y28	Y35
a	20	20	14	18	20	20	20
b	13	6	14	15	15	15	15
c	16	16	22	18	16	16	16
d	30	37	29	28	28	28	28

Her topoloji için olasılık tablosu kullanılarak hesaplanan istatistiksel değerler aşağıdaki tablolarda verilmiştir.



Tablo 5.6. Her topolojinin eğitim setine ait istatistiksel değerler

	Y4	Y7	Y10	Y14	Y21	Y28	Y35
POD (%)	53,87	61,63	70,61	81,22	88,57	92,65	82,44
FAR(%)	28,64	28,43	21	8,29	6,06	4,62	3,8
CSI(%)	44,29	49,5	59,45	75,66	83,78	88,67	79,84
ACC(%)	72,33	74,33	80,33	89,33	93	95,16	91,5
BIAS	75,51	86,12	89,38	88,57	94,28	97,14	85,71
POFD(%)	14,92	16,9	12,95	5,07	3,94	3,09	2,25
H-D SKILLS(%)	38,94	44,73	57,65	76,15	84,62	89,55	80,19
O-R	6,6562	7,898	16,14	80,99	188,7678	394,3838	203,7616

Tablo 5.7. Her topolojinin test setine ait istatistiksel değerler

	Y4	Y7	Y10	Y14	Y21	Y28	Y35
POD (%)	55,55	55,55	38,88	50	55,55	55,55	55,55
FAR(%)	60,6	76,92	50	54,54	57,14	57,14	57,14
CSI(%)	40,81	47,61	28	35,29	39,21	39,21	39,21
ACC(%)	63,29	72,15	54,43	58,22	60,75	60,76	60,75
BIAS	91,66	72,22	77,77	91,66	97,22	97,22	97,22
POFD(%)	30,23	13,95	32,55	34,88	34,88	34,88	34,88
H-D SKILLS(%)	25,32	41,6	63,3	15,11	20,67	20,67	20,67
O-R	2,8846	7,7083	1,3181	1,867	2,333	2,333	2,333

Hesaplanan istatistikler yardımıyla değişik YSA modellerinin performanslarını karşılaştırabiliriz. Önemli olan kurulan sistemin Tahmin Doğruluğunun (POD) ve Kritik Başarı Endeksinin (CSI) yüksek olması, buna karşılık Yanlış Tahmin Etme (POFD) veya Yanlış Alarm Oranının (FAR) düşük olmasıdır.

Bu kriterlere göre bir modelin Tahmin Doğruluğu yüksek iken Yanlış Alarm Oranı da yüksek çıkabilir; veya diğer kriterler birbiriyle ters düşebilir. Bu durumda bazı özelliklerden feragat etmemiz gerekmektedir.

Tablo 5.6 da görüldüğü gibi 28 gizli nöronlu Yapay Sinir Ağı modeli eğitim setinde diğerlerine göre daha iyi performans göstermektedir. POD, CSI, ACC ve POFD değerleri yüksek, FAR değeri ise 35 nöronlu YSA yapısı ile birlikte en düşük değerlere sahiptir. Buna göre eğitim seti için en iyi network topolojisinin bu olduğuna karar verebiliriz.

Amacımız ileriye yönelik ‘Satın al’ veya ‘Satın alma’ kararı vermek olduğu için bizim için önemli olan bir modelin ileriye yönelik performansının iyi olmasıdır. Bu performansı belirleyebilmek için Tablo 5.7. de verilen test seti istatistik değerlerine bakmamız gerekmektedir. Tablo incelendiğinde Tahminin Doğruluğu (POD) değerlerinin hemen hemen her topoloji için aynı olduğu görülmektedir. Doğruluk (ACC) değerleri kıyaslandığında, gizli katmanında 7 nöron bulunan topolojinin (Y7) diğer yapılara oranla yaklaşık %10 daha fazla doğrulukla tahmin yaptığı anlaşılmaktadır. Diğer bir önemli değişken olan Kritik Başarı Endeksi (CSI) göz önüne alındığında yine 7 nöronlu yapının diğer yapılar karşısında belirgin bir üstünlüğü olduğu gözlenmektedir. Yanlış Tahmin Etme Olasılığının (POFD) Y7 de yüksek olması yukarıda bahsettiğimiz ‘bazı özelliklerden feragat etme’ sonucunu doğurmaktadır. Bu sonuçlar altında ileriye yönelik ‘Satın al’ veya ‘Satın alma’ kararı verebilecek en uygun ve güvenilir yapının gizli katmanında 7 nöron bulunan, geri yayılım öğrenme algoritmasına göre çalışan ve çok katmanlı algılayıcı temel yapısına sahip Yapay Sinir Ağı modeli olduğunu söyleyebiliriz.



6. SONUÇ VE ÖNERİLER

Yapay Zeka, son yarım yüzyıldır araştırmacıların ilgisini çeken ve teknolojinin gelişmesiyle yeni kullanım alanları keşfedilen önemli bir bilim dalıdır. ‘Bilgisayarın düşünebilmesi’ temel felsefesinden yola çıkılarak, savunma sanayinden ekonomiye kadar pek çok farklı alanda insanlara alması gereken önemli kararlarda yol gösterecek sistemler geliştirmek, konu hakkında çalışmalar yapan bilim adamlarının temel hedefidir. Ekonomi ve finans dünyasında da başta A.B.D. olmak üzere pek çok gelişmiş ülkede kullanılan Yapay Zeka teknikleri sayesinde beşeri hatalar en aza indirgenmekte ve doğru kararların alınması bilgisayar sistemlerine bırakılarak yatırımın optimum düzeyde geri dönüşü sağlanmaktadır.

Yurt dışında Yapay Zeka için bir öğrenme algoritması olan Yapay Sinir Ağları’nın finans sektöründe uygulanışı genellikle geçmiş dönem hisse fiyatlarından yola çıkılarak ileriye yönelik hisse fiyatlarının tahmin edilmesi şeklinde olmaktadır. Çalışmamızın literatüre getirdiği yenilik ‘Yapay Sinir Ağları’nı kullanarak hisse seçimini bilgisayara yaptırmak’ olarak özetlenebilir.

Yapay Sinir Ağları’nın en önemli özelliklerden birisi ağı yapısının sadece eldeki örneklerle göre ayarlanmasıdır. Bunun anlamı veri setine yeni örnekler girildiğinde ağın topolojik yapısının yani gizli katman nöron sayısının değişeceğidir. Her ağ yapısı için yaptığımız istatistik hesapları karşılaştırarak önerdiğimiz ağ yapısı sadece bizim veri setimiz için geçerlidir. Unutulmamalıdır ki, önerdiğimiz ağ yapısı maksimum performansı değil optimum performansı sergileyecek şekilde seçilmiştir.

‘Yapay Sinir Ağları ile borsada hisse seçimi’ konulu çalışmamızda Türkiye borsasını seçemeyişimizin sebebi girdi seti olarak kullandığımız değişkenlerin Türkiye borsasında kolay elde edilememesidir. Gelişmekte olan bir yapıya sahip Türkiye ile paralel özelliğe haiz Türkiye borsasında Veri Madenciliği ve Yapay Zeka uygulamaları için biraz daha zaman gerekmektedir.

Yapay Sinir Ağları, finans sektöründe dünyanın dört bir yanında uygulama alanları bulmaktadır. Biz, çalışmamızda Yapay Zeka’nın hisse senedi seçiminde

yatırımcılara yararlı olabileceğini göstermeye çalıştık. Organize olmuş, bilgilere kolay ulaşılabilen bir Türkiye borsasında da gelecekte bu konuda çalışmalar yapılacağı şüphesizdir.



KAYNAKLAR

Abarbanell, J.S. and Bernard, V., *Test of Analysts, Overreaction/Underreaction to Earnings Information as an Explanation for Anomalous Stock Price Behavior*, Journal of Finance, 1992, p: 1181-1207.

Amari, S., Arbib, M., *Competition and Cooperation in Neural Nets*, Academic Pres, New York, 1977, p: 119-165

Anand, T., *Opportunity Explorer: Navigating Large Databases Using Knowledge Discovery Templates*, Journal of Intelligent Information Systems 4, p: 27-38, 1995

Anderson, J., *Neurocomputing*, The MIT Press, 1988

Arbib, M.A., *Brains, Machines and Mathematics*, 2nd Edition, New York, 1987

Arnold, G., *Corporate Financial Management*, Prentice Hall, First Edition, 1998

Atiase, Rowland K., *Predisclosure Information, Firm Capitalization and Security Price Behavior Around Earnings Announcements*, Journal of Accounting Research, V: 23, 1985, p: 21-36

Ball, R. and Brown, P., *An Emprical Evaluation of Accounting Numbers*, Journal of Accounting Research, 1968, p:159-178

Barr, D.S. and Mani, G., *Using Neural Nets to Manage Investments*, AI Experts, p:16-21, 1994

Beaver, W.H., *Financial Reporting: An Accounting Revolution*, Prentice Hall, Third Edition, 1998

Beechey, M., Gruen, D. and Vickery, J., *The Efficient Market Hypothesis*, Economic Research Department, Reserve Bank of Australia, Paper no: 2, 2000

Bernard, V. and Jacob, T., *Evidence That Stock Price Do Not Reflect the Implications of Current Earnings for Future Earnings*, Journal of Accounting and Economics, 1981, p: 305-340

Berry, M.J., Linoff, G.S., *Mastering Data Mining*, John Wiley & Sons Inc, New York, 2000

Berson, A. and Smith, S.J., *Data Warehousing, Data Mining and OLAP*, McGraw-Hill, New York 1997

Bloomfield, R., Libby, R. and Nelson, M., *Over Reliance on Previous Period's Earnings Can Cause Post-Earnings-Announcement Drift and Over-Reactions to Extreme Performance?*, Social Science Research Network, Working Paper Series, 1998, p:1-35

Bloomfield, R., Libby, R. and Nelson, M., *Underreactions, Overreactions and Moderated Confidence*, Journal of Financial Markets, V: 3, 2000, p:113-137

Brachman, R.J., Khabaza, T., Kloesgen, W., Piatetsky-Shapiro, Simoudis, E., *Mining Business Databases*, Communications of the ACM 39, p: 42-48, 1996

Brown, L. and Kim, K., *The Association Between Nonearnings Disclosures by Small Firms and Positive Abnormal Returns*, The Accounting Review, V: 68, 1993, p: 668-681

Brown, S., *Earnings Changes, Stock Prices and Market Efficiency*, Journal of Finance, 1978, p: 17-28

Chopra, N., Lakonishok, J. and Ritter, J., *Measuring Abnormal Performance: Do Stocks Overreact?*, Journal of Financial Economics, V: 31, 1992, p: 235-268

Churchland, P.M., *Could a Machine Think?*, Scientific American, 1990

Clinch, G. and Sinclair, N., *Intra-Industry Information Releases: A Recursive System Approach*, Journal of Accounting and Economics, V: 9, 1987, p: 89-106

Cootner, P., *Stock Prices: Random Walk vs. Systematic Changes*, Industrial Management Review, 1962, p: 24-25

Cross, F., *The Behavior of Stock Prices on Fridays and Mondays*, Financial Analysts Journal, V: 29, 1973, p: 67-69

David, R.M., *A Perspective on Statistical Tools for Data Mining Applications*, <http://lac.uic.edu>, 2001

Derks, E.P.P.A., Sanchez Pastor, M.S., and Buydens, L.M.C. *Chemom. Intell. Lab. Syst.* 28,1995

De Bondt, W. and Thaler, R., *Does the Stock Market Overreact?*, Journal of Finance, V: 55, 1985, p: 793-805

Dreyfus, H.L., *Mind Over Machine, The Power of Human Intuition and Expertise in the Era of the Computer*, New York, 1986

Eggermont, J.J., *The Correlative Brain: Theory and Experiment in Neural Interaction*, New York, 1990

Elmas, Ç., *Yapay Sinir Ağları*, Seçkin Yayıncılık, Ankara, 2003

Fama, E., *Efficient Capital Markets: II*, Journal of Finance, V: 46, 1991, p: 1575-1617

Fama, E., Fisher, L., Jensen, M. and Roberts, R., *The Adjustment of Stock Prices to New Information*, International Economic Review, V: 10, 1969, p:1-21

Fayyad, U., Smyth, P., *From Data Mining to Knowledge Discovery in Databases*, AI Magazine, p: 37-53, 1996

Fayyad, U., Smyth, P., Uthuruswamy, R., *Advances in Knowledge Discovery and Data Mining*, AAAI Press/MIT Press, Cambridge, p: 495-515, 1996

Fiegenbaum, E., Cohen, P., *The Handbook of Artificial Intelligence*, vol: 3, MA, Addison Wesley, 1982

Foster, G., Olsen, C. and Shelvin, T., *Earnings Releases, Anomalies and the Behavior of Security Returns*, The Accounting Review, 1984, p: 574-603

Freeman, R. and Ayers, B., *Why Do Large Firms' Prices Anticipate Earnings Earlier Than Small Firms' Prices?*, Social Science Research Network, Paper no:000208306, 2000, p:1-28

Freeman, R. and Tse, S., *The Multipriod Information Content of Accounting Earnings: Confirmations and Contradictions of Previous Earnings Reports*, Journal of Accounting Research, 1989, p: 49-79

Freeman, R., *The Association Between Accounting Earnings and Security Returns of Large and Small Firms*, Journal of Accounting and Economics, V: 9, 1987, p: 195-228

Fukushima, K., *Neocognitron, A Hierarchical Neural Network Capable of Visual Pattern Recognition*, Neural Networks, vol: 1, p:119-130, 1988

Galindo, J., *A Framework for Comparative Analysis of Statistical and Machine Learning Methods: An Application to the Black Scholes Option Pricing Equation*, Technical Report, Banco de Mexico, Mexico, DF, 04930, 1998

Gardner, H., *Multiple Intelligences, The Theory in Practice*, Basic Books, 1993

Gardner, H., *Intelligence Reframed, Multiple Intelligence for the 21. Century*, New York, Basic Books, 1999

Geman, S., Bienenstock, E., and Doursat, R., *Neural Comput.*, 4 (1992) .

Glymour, C., Madigan, D., Smyth, P., *Statistical Themes and Lessons for Data Mining*, Data Mining and Knowledge Discovery 1, p: 11-28, 1997

Goodacre, R., Neal, M.J., and Kell, D.B., *Anal. Chem.*, 66 , p: 1070 ,1994

Grefenstette, J.J., *Optimisation of Control Parameters for Genetic Algorithms*, Man and Cybernetics, vol: 16, p: 122-128, 1986

Griffin, D. and Tversky, A., *The Weighing of Evidence and the Determinants of Confidence* , Cognitive Psychology, V: 24, p: 411-435, 1992

Grossberg, S., *Adaptive Pattern Classification and Universal Recoding*, Biological Cybernetics, 23, p: 121-134, 1976

Grossberg, S., *Competitive Learning, From Interactive Activation to Adaptive Resonance*, Cognitive Science, vol: 11, p: 23-63, 1987

Güngör, B., *Finans Literatüründe Anomali Kavramı ve Etkin Piyasalar Hipotezi*, Atatürk Üniversitesi İktisadi İdari Bilimler Fakültesi Dergisi, 2003

Han, J. and Wild, J., *Predisclosure Information, Firm Capitalization and Earnings Information Transfers*, Journal of Business Research, V: 49, 2000, p: 273-288

Haugen, R., *Modern Investment Theory*, Prentice Hall, 2001

Haykin, S., *Neural Networks: A Comprehensive Foundation*, 2nd Edition, Prentice Hall, 1999

Hebb, D.O., *The Organization of Behavior*, John Wiley & Sons, New York, 1949

Holland, J.H., *Adaptation in Natural and Artificial Systems*, University of Michigan Press, 1975

Hornik, K., Stinchcombe, M., and White, H., *Neural Networks*, 2 (1989) p: 359.

Howe, J., *Evidence on Stock Market Overreactions*, Financial Analysis Journal, 1986, p: 74-77

Hutchinson, J.M., Lo, A.W. and Poggio, T., *A Nonparametric Approach to Pricing and Hedging Derivative Securities Via Learning Networks*, The Journal of Finance, XLIX (3), p: 851-889, 1994

İnce, H., *Veri Madenciliği Ders Notları*, GYTE, 2004

İnce, H., Theodore, B., *An Intelligent System: Support Vector Machines for Portfolio Selection*, In Neural Networks, 2000

İpekten, O., *Sermaye Piyasası Ders Notları*, Atatürk Üniversitesi İktisadi ve İdari Bilimler Fakültesi, No: 214, 1999

Jackson, P., *Introduction to Expert Systems*, International Computer Science Series, 1999

Jegadeesh, N. and Titman, S., *Returns to Buying Winners and Selling Losers: Implications for Stock Market Efficiency*, Journal of Finance, 1993, p: 65-91

Jensen, M., *Some Anomalous Evidence Regarding Market Efficiency*, Journal of Financial Economics 6, p : 95, 1978

Kaplan, A., Özer, Ş., Sağiroğlu, Ş., *Rulebase Determination and Membership Function Optimization of a Fuzzy Logic Controller Using Modified Tabu Search Algorithm*, Conference of North American Fuzzy Information Processing Society, Florida USA, p: 64-67, 1998

Karaboğa, D., *A Modified Genetic Algorithm for Function Optimization*, The Fourth Turkish Symposium on Artificial Intelligence and Neural Networks, Marmara Research Center, Gebze - Kocaeli, p: 255-262, 1994

Kohonen, T., *Self-Organized Formation of Topologically Correct Feature Maps*, Biological Cybernetics, v: 43, p: 59-69, 1982

Kohonen, T., *Statistical Pattern Recognition With Neural Networks, Benchmarking Studies*, IEEE International Conference on Neural Networks, p: 61-67, San Diego, 1988

Kolen, J.F., and Pollack, J.B., *Advances in Neural Information Processing Systems*, vol.3, ed. Lippmann, R.P., Moody, J.E., and Touretzky, D.S., Morgan Kaufmann, San Mateo, CA, 1991.

Konar, A., *Artificial Intelligence and Soft Computing*, CRC Press, 2000

Kosko, B., *Neural Networks and Fuzzy Systems, a Dynamical Systems Approach to Machine Intelligence*, Prentice-Hall International Editions, N.J., 1992

Liao, S., Pawlak M., *Array Pattern Synthesis With Null Steering Using Genetic Algorithms by Controlling Only The Current Amplitudes*, Int. J. Electron, v: 86, p: 445-457, 1999

Lippmann, R.P., *IEEE Trans. Neural Networks*, 5 , p: 1061, 1995.

Malkiel, B., *Efficient Market Hypothesis*, New Palgrave Dictionary of Money and Finance, London, McMillan, 1992

Masters, T., *Practical Neural Network Recipes in C++*, Academic Press, Boston, 1993.

Milis, T.C., *Non-linear Time Series Models in Economics*, J.Econ.Surv.5, p: 215-241, 1990

Minsky, M.L., Papert S.A., *Perceptrons*, MIT Press, Cambridge, 1988

Mitchell, T.M., *Machine Learning*, McGraw Hill, 1997

Morse, D., *Price and Trading Volume Reactions Surrounding Earnings Announcements: A Closer Examination*, Journal of Accounting Research, 1983, p: 374-383

Özdamar, K., *Paket Programlar ile İstatistiksel Veri Analizi 2*, Kaan Kitapevi, s: 499, Eskişehir, 1999

Özer, G., *Hisse Senedi Piyasalarında Uzun Süreli Getiri Zıtlıkları: Aşırı Tepki Verme Hipotezi ve Bir Değerlendirme*, www.basarim.com.tr/dergi, 2000

Özer, G., *Muhasebe Karları ile Hisse Senedi Verimleri Arasındaki İlişkiler: İMKB'de Deneyisel Bir Analiz*, Sermaye Piyasası Kurulu, Yayın No: 31, 1996

Özmen, T., *Dünya Borsalarında Gözlemlenen Anomaliler ve İMKB Üzerine Bir Deneme*, Sermaye Piyasası Kurulu, Yayın No: 61, 1997

Öztemel, E., *Yapay Sinir Ağları*, Papatya Yay., İstanbul, 2003

Patell, J. and Wolfson, M., *The Intraday Speed of Adjustment of Stock Prices to Earnings and Dividend Announcements*, Journal of Financial Economics, V: 13, 1984, p: 223-252

Penrose, R., *The Emporer's New Mind, Concerning Computers, Minds and the Laws of Physic*, Oxford UK, 1987

Pettengill, G. and Buster, D., *Variation in Return Signs: Announcements and the Weekday Anomaly*, Quarterly Journal of Business and Economics, V: 33, 1994

Pettengill, G. and Jordan, B., *A Comprehensive Examination of Volume Effects and Seasonality in Daily Security Returns*, Journal of Financial Research, v: 11, 1988, p: 57-70

Pettengill, G., *Daily Return Correlations: A Reewamination*, Quarterly Journal of Business and Economics, V: 28, 1989, p: 123-141

Pettit, R., *Dividend Announcements, Security Performance and Capital Market Efficiency*, Journal of Finance, 1972, V: 27, p: 993-1003

Pham, D.T., Karaboğa, D., *Intelligent Optimisation Techniques, Genetic Algorithms, Tabu Search, Simulated Annealing and Neural Networks*, Springer, Verlag, London, 2000

Rauch, J., Berka, P., *Knowledge Discovery in Financial Data- A Case Study*, Neural Network World 4, p: 427-437, 1997

Redhouse Sözlüğü, Redhouse Yayınevi, 22.Baskı, 1995

Reeves, C.R., *Modern Heuristic Techniques for Combinatorial Problems*, McGraw-Hill, UK, 1995

Ronald, S., *Accelerating Customer Relationship*, Prentice Hall PTR, 2001

Rosenblatt, F., *The Perceptron, a Probabilistic Model for Information Storage and Organization in the Brain*, Psychological Review, vol: 65, p: 386-408, 1958

Rumelhart, D.E., Hinton, G.E., Williams, R.J., *Learning Representations of Back-Propagation Errors*, Nature vol: 323, p: 533-536, 1986

Russell, S.J., Norvig, P., *Artificial Intelligence: A Modern Approach*, Prentice-Hall, 1995

Sağıroğlu, Ş., Beşdok, E., Erler, M., *Mühendislikte Yapay Zeka Uygulamaları: Yapay Sinir Ağları*, Ufuk Yayınevi, 2003

Searle, J., *Minds, Brains and Programs*, The Behavioral and Brain Sciences, vol: 3, 1980

Searle, J., *Is the Brain's Mind a Computer Program?*, Scientific American, 1990

Sloan, R., *Do Stock Prices Fully Reflect Information in Accruals and Cash Flows About Future Earnings?*, Accounting Review, 1996, p: 289-315

Spangler, W., May, J.H., Vargas, L.G., *Choosing Data Mining Methods for Multiple Classification: Representational and Performance Measurement Implications for Decision Support*, Journal of Management Information Systems 16, p: 47-62, 1999

Tatlıdil, H., *Uygulamalı Çok Değişkenli İstatistiksel Analiz*, Akademi Matbaası, s: 424, Ankara, 2002

Thaler, R., *Behavioral Economics*, NBER Raporter, p: 9-13, 1995

Trafalis, T.B., White, A., and Frass, A., *Data Mining Techniques for Tornadoic Pattern Recognition*, Intelligent Engineering Systems Through Artificial Neural Networks, Vol: 10, p: 455-460, ASME, 2000

Widrow, B., Lehr, M.A., *30 Years of Adaptive Neural Networks, Perceptrons, Madaline and Backpropagation*, Proc. IEEE, vol: 78, p: 1415-1442

Williams, R.J., *A Learning Algorithm for Continually Running Fully Recurrent Neural Networks*, Neural Computation, vol:1, p: 270-275, 1989

Wilson, R.L. and Sharda, R., *Bankruptcy Prediction Using Neural Networks*, Decision Support Systems 11, p: 545-557, 1994

Winston, H., *Artificial Intelligence*, 3rd Edn. Addison-Wesley, 1992

Yuanhui, Z., Yuchang, L., Chunyi, S., *Combining Neural Network, Genetic Algorithm and Symbolic Learning Approach to Discover Knowledge from Databases*, Man and Cybernetics, Vol: 5, Orlando FL, p: 4338-4393, 1997

Zeghal, D., *Firm Size and Informational Content of Financial Statement*, Journal of Financial and Quantitative Analysis, 1984, p: 299-310

Zurada, J.M., *Introduction to Artificial Neural Networks*,
Company, 1992



Internet siteleri:

www.briefing.com

www.yahoo.com/finance



ÖZGEÇMİŞ



1980 yılında İstanbul’da doğan M.Erkut Erdinç ilk, orta ve lise eğitimini Gebze ‘de tamamladı. 1998 yılında girdiği Kocaeli Üniversitesi’nden 2003 yılında Makine Mühendisi olarak mezun oldu. Aynı yıl kabul edildiği Gebze Yüksek Teknoloji Enstitüsü Strateji Bilimi Yüksek Lisans programından mezun olma aşamasındadır.

İyi derecede İngilizce, başlangıç düzeyinde Almanca bilmektedir.

