

126697

YAPAY SİNİR AĞLARI YARDIMI İLE
DİNAMİK BİR SENARYO ANALİZİ

DOKTORA TEZİ
Y. Müh. Şule ÖNSEL ŞAHİN
(507960103012)

TEZ YERİNE GÖRÜLME KURULU
DOKÜMAN TAYİN MERKEZİ

Tezin Enstitüye Verildiği Tarih : 2 Ağustos 2001
Tezin Savunulduğu Tarih : 10 Mayıs 2002

Tez Danışmanı : Prof.Dr.Fusun ÜLENGİN

Diğer Jüri Üyeleri Prof.Dr. Ataç SOYSAL (İ.T.Ü.)

Prof.Dr. İlhan OR (B.Ü.)

Prof.Dr. Gündüz ULUSOY (S.Ü.)

Doç.Dr. Burç ÜLENGİN (İ.T.Ü.)

MAYIS 2002

126697

ÖNSÖZ

Hayatımda yoğun olarak emek harcadığım ve birbirleriyle kesişen bir zaman diliminde benim için zorlukları da mutlulukları da ikiye katlayan iki ayrı olayı; oğlumu ve doktora tezimi; bu günlerden sonra birbirinden ayrı değerlendirebileceğimi zannetmiyorum. Bu süreç boyunca, dış çıkarma sancılarının, tezin uygulamasında karşılaştığım bir problemle aynı zamana rastlamasının uykusuz geceleri iyice uzattığı da oldu; ilk adımların verdiği mutluluğun, yaptığım enflasyon tahmininin test başarısına karıştığı da...Sonuçta, oğlum hemen hemen 2.5 yaşında ve bence “kocaman bir adam” oldu ve bunlar da sanırım tezimin son satırları...

Bu günler boyunca; önerileri, destekleri ve ilgileriyle yanımda olan ve teşekkür etmem gereken kişiler var şüphesiz...

Danışmanım Prof. Dr. Füsun Ülengin'e, çalışmalarına verdiği destek, çizdiği yönün yanı sıra; bir hocadan çok öte, sevinç ve üzüntülerimi benimle paylaşan vazgeçilmez, bir dost olduğu için;

Doç.Dr.Burç Ülengin'e, başım her sıkıştığında bana zaman ayırdığı için;

Annem ve ablam, Hatice ve Şefika Önsel'e, sevgilerini, ilgilerini ve desteklerini, sonsuz ve sitemsiz bir şekilde bana sundukları için;

Eşim Serkan Şahin'e, tez yazma sırasındaki bunalımlarımı her zamanki sabrı ve hoşgörüsü ile benimle paylaştığı için;

Ve oğlum Ozan'a; ağlamaları ve uykusuz geceleri ile zaman zaman çalışmalarımı kösteklese de; varlığını öğrendiğim ilk günden beri sağladığı motivasyon; gülücükleriyle bana verdiği coşku için teşekkür ederim...

Umarım bu doktora çalışması bu alandaki yeni çalışmalar için bir başlangıç noktası oluşturabilir...

Haziran 2002

Şule ÖNSEL ŞAHİN

İÇİNDEKİLER

KISALTMALAR	vi
TABLO LİSTESİ	vii
ŞEKİL LİSTESİ	viii
SEMBOL LİSTESİ	ix
ÖZET	x
SUMMARY	xii
1. SENARYO ANALİZİ	1
1.1. Senaryo Analiz Süreci	4
1.2. Senaryo Analiz Yaklaşımları	11
1.2.1. Sezgisel Mantık	11
1.2.2. Eğilim-Etki Analizi	14
1.2.3. Çapraz-Etki Analizi	17
1.3. Senaryoların Fonksiyonları	22
1.4. Senaryo Analizinin Sonuçları	24
1.5. Senaryoların Yapıları	25
1.6. Senaryo Analizinin Geliştirilmesi	29
2. EFAR YAKLAŞIMI	31
2.1. Temel Değişkenlerin Listelenmesi	33
2.2. Değişken Düzeylerinin Belirlenmesi	33
2.3. Anlamsız Bileşimlerin Elenmesi	34
2.4. Olurlu Bileşimlerin Kümelenmesi	36
2.5. Geçiş Matrisinin Oluşturulması	37
2.6. Geçiş Matrisinin Çizgelere Aktarılması	41

2.7. Efar Yaklaşımının Zayıf Yönleri	42
3. BİLİŞSEL HARİTALAR	43
3.1. Bilişsel Haritaların Oluşturulması	45
3.2. Bilişsel Haritalarda Matematiksel Yapı	48
3.3. Bilişsel Haritaların Özellikleri	50
3.4. Bilişsel Haritaların Analizi	52
3.4.1. Bilişsel Haritalar'ın Analizinde Döngüler	53
4. YAPAY SİNİR AĞLARI	58
4.1. Yapay Sinir Ağlarının Temel Yapısı	60
4.2. Yapay Sinir Ağlarında Öğrenme	61
4.2.1. Gözetimli Öğrenme	62
4.2.1.1. Algılayıcılar	63
4.2.1.2. Çok Katmanlı İleri Beslemeli Ağlar	65
4.2.1.2.1. Geri Yayılmalı Öğrenme Algoritması İçin Bir Örnek	71
4.2.1.2.2. Öğrenme Parametrelerinin Belirlenmesi	77
4.2.2. Gözetimsiz Öğrenme	83
4.2.3. Karma (Reinforcement) Öğrenme	86
4.3. Girdi Sinir Hücrelerinin Önem Sıralaması	87
4.4. YSA'nın Tahmin Modelleri İçin Kullanımı	89
4.5. YSA'nın Kümeleme Analizi İçin Kullanımı	92
5. MATLAB YAZILIMI	95
5.1. Bilgisayar Desteğinin Gerekliliği	95
5.2. Hareket Fonksiyonları	95
5.3. Başlangıç Fonksiyonları	96
5.3.1. Initff Fonksiyonu	96
5.3.2. Inite Fonksiyonu	97
5.4. Eğitim Fonksiyonları	97
5.4.1. Trainbp Fonksiyonu	97
5.4.2. Trainbpx Fonksiyonu	98
5.4.3. Trainc Fonksiyonu	99

5.5. Simulasyon Fonksiyonları	99
5.5.1. Simuff Fonksiyonu	99
5.5.2. Simuc Fonksiyonu	99
5.6. Gözetimli Öğrenme için Bir Örnek	100
5.7. Gözetimsiz Öğrenme için Bir Örnek	102
6. UYGULAMA	104
6.1. Yöntem	104
6.1.1. Sektörlerin Belirlenmesi	106
6.1.1.1. Bilişsel Haritalar Yaklaşımı	106
6.1.1.2. Yapay Sinir Ağları Yaklaşımı	118
6.1.2. Gelecekle İlgili Tüm Durumların Ortaya Konması	124
6.1.3. Anlamsız Bileşimlerin Elenmesi	125
6.1.3.1. Kümeleme ve Korelasyon Analizleri	125
6.1.4. Olurlu Bileşimlerin Kümelenmesi	125
6.1.5. Durumlar Arası Geçişin Belirlenmesi	126
6.1.6. Gelecek Görüntülerinin Çizgelere Aktarılması	127
7. SONUÇ VE ÖNERİLER	135
KAYNAKLAR	139
EKLER	146
EK A	147
EK B	151
EK C	157
EK D	159
EK E	164
EK F	166
EK G	169
ÖZGEÇMİŞ	171

KISALTMALAR

GSMH	: Gayri Safi Milli Hasıla
FAR	: Field Anamoly Relaxation
EFAR	: Extended Field Anamoly Relaxation
BH	: Bilişsel Harita
MICMAC	: Matrice d'Impacts Croisés-Multiplication Appliquée a un Classement / Cross Impact Matrix-Multiplication Applied to Classification
YSA	: Yapay Sinir Ağı
XOR	: Exclusive-or
AR	: Auto Regressive
MA	: Moving Average
ARIMA	: Auto Regressive Integrated Moving Average
MSE	: Mean Square Error - Hataların Karesinin Ortalaması
RMSE	: Root Mean Square Error - Hataların Karelerinin Ortalamasının Karekökü
RELRMSE	: Relative Root Mean Square Error - Göreli Hataların Karelerinin Ortalamasının Karekökü
MRE	: Mean Relative Error - Ortalama Göreli Hata
sse	: Sum Square Error - Hata Karelerinin Toplamı
me	: Maksimum Epoch - En Fazla Devir Sayısı
tp	: Training Parameters – Öğretim Parametreleri
df	: Display Frequency - Devirler Arası Gösterim Sıklığı
lr	: Learning Rate - Öğrenme Oranı

TABLO LİSTESİ

	<u>Sayfa No</u>
Tablo 2.1 Örnek Değişken-Düzey Tablosu	34
Tablo 2.2 Kontrol Matrisi	34
Tablo 2.3 Uygunluk Matrisi	35
Tablo 2.4 Uygun Durumların Listesi	37
Tablo 2.5 Gruplanmış Uygun Bileşimler	38
Tablo 2.6 Geçiş Matrisi İçin Uzaklıklar.....	39
Tablo 2.7 Geçiş Matrisi	40
Tablo 3.1 Komşuluk Matrisi	53
Tablo 3.2 Örnek Bir Komşuluk Matrisi	54
Tablo 3.3 Basit Forma Dönüştürülmüş Komşuluk Matrisi	55
Tablo 4.1 Örnek Problem İçin Eğitim Verileri.....	71
Tablo 4.2 Gizli Ve Çıktı Hücreleri İçin Girdi Ve Çıktı Değerleri.....	73
Tablo 4.3 12 Ayrı Veri İçin Hata Değerleri Ve Toplam Hata.....	74
Tablo 4.4 Gizli Ve Çıktı Hücreleri İçin δ Değerleri.....	75
Tablo 4.5 Güncellenmiş Ağırlık Değerleri.....	76
Tablo 4.6 Gizli Sinir Hücresi Sayısının Hata Üzerindeki Etkisi	78
Tablo 6.1 Prof.Dr.Nurhan Yentürk`ün İkili Karşılaştırma Matrisi.....	107
Tablo 6.2 Doç.Dr.Lerzan Özkale`nin İkili Karşılaştırma Matrisi	108
Tablo 6.3 Doç.Dr.Burç Ülengin`in İkili Karşılaştırma Matrisi	111
Tablo 6.4 Toplu İkili Karşılaştırmalara Matrisi	113
Tablo 6.5 Çıktı Verilerinin Karşılaştırılması.....	120
Tablo 6.6 Farklı Rassal Başlangıç Ağırlıklarına Ait MSE Değerleri.....	120
Tablo 6.7 Sonuçların Karşılaştırılması.....	122
Tablo 6.8 Girdi Değişkenlerinin Önem Sıralaması	123
Tablo 6.9 Gelecekle İlgili Tüm Durumların Listesi	127
Tablo 6.10 Temel Senaryolar Ve Bileşenlerin Ortalama Değerleri	130
Tablo 6.11 İlk Örnek İçin Veriler	131
Tablo 6.12 İlk Örnek İçin Kontrol Verileri	131
Tablo 6.13 İkinci Örnek İçin Veriler	132
Tablo 6.14 İkinci Örnek İçin Kontrol Verileri	132
Tablo 6.15 Üçüncü Örnek İçin Veriler	133
Tablo 6.16 Üçüncü Örnek İçin Kontrol Verileri	133
Tablo A.1 Ocak 1994-Aralık 1998 İçin Veriler.....	147
Tablo C.1 Gelecek Görüntülerinin Listesi	157
Tablo E.1 Kümeleme ve Korelasyon Analizleri Sonuçları.....	164

ŞEKİL LİSTESİ

Sayfa No:

Şekil 1.1 Senaryo Geliştirme Süreci	6
Şekil 1.2 Çapraz Etki Analizi için Süreç Önerisi.....	19
Şekil 1.3 Planlama Yaklaşımları	26
Şekil 2.1 EFAR Yaklaşımının Adımları.....	32
Şekil 3.1 Örnek Bir Bilişsel Harita	52
Şekil 4.1 Yapay Sinir Ağlarının Temel Yapısı	60
Şekil 4.2 Örnek Bir Yapay Sinir Ağı	61
Şekil 4.3 Doğrusal Olarak Ayrılamayan XOR Problemi	64
Şekil 4.4 Doğrusal Olarak Ayrılabilen Bir Problem Örneği	64
Şekil 4.5 XOR Problemini Çözen Yapay Sinir Ağı Yapısı	65
Şekil 4.6 Yapay Bir Sinir Hücresi.....	67
Şekil 4.7 Örnek Problem için Yapay Sinir Ağı Yapısı	72
Şekil 4.8 Eğitim İterasyon Sayısı	80
Şekil 5.1 Log-Sigmoid Tipi Hareket Fonksiyonu	96
Şekil 5.2 Tan-Sigmoid Tipi Hareket Fonksiyonu	96
Şekil 6.1 Uygulamada İzlenen Süreç	105
Şekil 6.2 Prof.Dr.Nurhan Yentürk'ün Bilişsel Haritası.....	107
Şekil 6.3 Doç.Dr.Lerzan Özkale'nin Bilişsel Haritası	108
Şekil 6.4 Doç.Dr.Burç Ülengin'in Bilişsel Haritası	110
Şekil 6.5 Toplu Bilişsel Harita.....	112
Şekil 6.6 Çıktı Verilerinin Karşılaştırılması	121
Şekil 6.7 Değişkenlerin Önem Sıralaması.....	124
Şekil 6.8 Senaryoların SPSS Yardımıyla Kümeleniş Gösterimi	126
Şekil 6.9 Senaryo İçi İlişkiler.....	128
Şekil 6.10 Senaryolar Arası İlişkiler.....	129

SEMBOL LİSTESİ

w_{ij}	: i-j Değişkenleri Arasındaki Kuvvet
T_i	: Eşik Derecesi
X_i	: Etki Vektörü
Y_i	: Çıktı Vektörü
$x(t)$	: Girdi Matrisi
$y(t)$	: Çıktı Matrisi
η	: Öğrenme Oranı
f	: Hareket Fonksiyonunu
y_i	: Çıktı Hücre Değeri
x_k	: Girdi Hücre Değeri
v_j	: Gizli Hücre Değeri
w_{jk}	: Girdi-Gizli Düzeyleri Arasındaki Bağlantıların Ağırlıkları
w_{ij}	: Gizli-Çıktı Düzeyleri Arasındaki Bağlantıların Ağırlıkları
p	: Örnek Sayısı
μ	: Farklı Örnek İndeksi
o_i	: Üretilen Çıktı
y_i	: Öğretim Hedefi
E	: Hata Fonksiyonu
α	: Momentum Sabiti
RS_{ji}	: i Girdisi ile j Çıktısı Arasındaki Bağın Kuvveti
K	: Komşuluk Matrisi
U	: Ulaşılabilirlik Matrisi
ϕ_d	: Çıkış Derecesi
g_d	: Giriş Derecesi
td	: Toplam Derece
G_i	: i. Gizli Hücre
$\mathcal{C}_i$	: i. Çıktı Hücresi
BP	: Back-Propagation – Geri Yayılma
N	: Girdi Sinir Hücresi Sayısı
M	: Çıktı Sinir Hücresi Sayısı
P	: Girdi Matrisi
T	: Çıktı Matrisi
S_l	: Gizli Düzeydeki Sinir Hücresi Sayısı
B	: Hata Terimi

YAPAY SINIR AĞLARI YARDIMI İLE DİNAMİK BİR SENARYO ANALİZİ

ÖZET

Geleceğin nasıl olacağı herkes için önemli ve merak uyandırıcı olsa da organizasyonlar için geleceğin belirsizliği ve karmaşıklığı önceden hazırlıklı olunması gereken en önemli problemlerden biridir. Zira, ancak, gelecekteki belirsizliklere karşı hazırlıklı olduğunda, etkin stratejiler üretilebilir. Senaryo analizi, işte bu belirsizlikle başa çıkmak için kullanılan en önemli araçlardan biridir. Senaryo analizleri ile gelecek tahmin edilemez, ama gelecekte olabilecek değişik durumlara karşı organizasyonların hazırlıklı olması sağlanabilir.

Bu tez çalışmasında, senaryo analizine daha dinamik bir boyut kazandırılması hedeflenmiş; bu amaçla EFAR–Durum Bozukluklarının Giderilmesi İçin İyileştirilmiş Bir Yaklaşım (Extended Field Anomaly Relaxation) yöntemi incelenmiş, farklı yöntemler yardımı ile yeni ve dinamik bir senaryo analiz yaklaşımı ortaya konulmuştur. Sözkonusu yaklaşımın geleneksel senaryo analizinden en önemli ayrıcalığı, kısıtlı sayıda ve birbirinden ayrık senaryolar yerine, çok sayıda ve birbirleri arasındaki geçişin olanaklı olduğu senaryolarla çalışmasıdır. Bu amaçla tezde, incelenilen EFAR yaklaşımının izlediği sürecin yoğun bir şekilde öznel bilgiye gereksinim duyması, yaklaşımın zayıf noktası olarak görüldüğünden, öznel bilgiden uzaklaşıp daha etkin ve nesnel bilgiye dayalı bir yaklaşım önerilmiştir.

Sürecin ilk aşamasında uzman görüşlerinin ortaya konması için bilişsel harita yaklaşımı kullanılmıştır. Bunu izleyen aşamalarında yani, incelenilen konunun temel özelliklerinin belirlenmesi, anlamsız bileşimlerin elenmesi, olurlu bileşimlerin kümelenmesi ve gelecek görüntülerinin temel senaryolar altında toplanması için ise yapay sinir ağları yoğun olarak kullanılmıştır. Bunun yanı sıra, gelecekle ilgili tüm durumların ortaya konması aşamasında bir Excel add-in programı olan SIM.xla'dan ve durumlar arası geçişin belirlenmesi için SPSS yazılımından yararlanılmıştır. Sonuçta, yoğun olarak yapay sinir ağları kullanımı ile çok sayıda ve birbirleri ile

ilişkili senaryolar ortaya konmuş ve bu senaryolar aracılığıyla analize dinamik bir boyut kazandırılmıştır.



A DYNAMIC SCENARIO ANALYSIS WITH THE HELP OF ARTIFICIAL NEURAL NETWORKS

SUMMARY

Although how the future will be is an important question for all of us, the uncertainty and complexity of the future is one of the major problems that organisations confront. Organisations can generate efficient strategies only when this uncertainty is managed. Scenario analysis is one of the important tools that is used to manage this uncertainty and complexity about the future. The future is not forecasted by scenario analysis but organisation are prepared for different probable situations that may take place in the future.

In this thesis, a better dynamism is aimed by making scenario analysis. Because of this reason EFAR approach is analysed and with the use of different methods a new and dynamic scenario analysis approach is proposed. The most important difference of the approach from the conventional scenario planning and analysis is that, it has the advantage of encompassing a large number of possible futures which are understood as a whole because of the process of considering what links each future with another. The main weakness of the EFAR procedure is that; it draws heavily on subjective business judgment. In this thesis, although the procedural discipline of EFAR is used; a more efficient and objective approach is proposed with the help of artificial neural networks and cognitive maps.

In the first stage of the process, cognitive mapping is used to highlight the decision structure of different decision makers. In the following stages, artificial neural networks is used to define the sectors of the subject, rejection of the infeasible combinations, clustering feasible combinations and grouping the many future states under the main scenarios. Besides, in order to define all the future states, an excel add-in program, namely SIM.xla, is used and the transitions between the states are examined by the help of SPSS software. As a result by the use of artificial neural

networks; many scenarios that are interrelated with each other are considered and a dynamic perspective is added to the scenario analysis.



1 SENARYO ANALİZİ

Strateji oluşturan yönetim grupları arasındaki anlaşmazlıkların temel nedeni hedefler ya da kişilikler değil, gelecekle ilgili olası düşünce ve varsayım farklılıklarıdır (Turner, 1995). Eğer stratejisi oluşturulmaya çalışılan çevrenin gelecekteki durumu hakkında belirsizlik varsa, strateji geliştirmek de doğal olarak zorlaşır. Bu zorluğun üstesinden gelmenin etkili bir yolu gelecekle ilgili alternatif durumların senaryolarını oluşturmaktır. Böylece mevcut duruma ne kadar yabancı olunursa olunsun her türlü potansiyel gelecek için senaryolar yardımıyla önceden hazırlıklı olunabilir.

Senaryo analizi, organizasyonun amaçlarına ulaşmasında büyük etkisi olan dış çevredeki değişimlere hazırlıklı olunmasına yardımcı olur (Weinstein, 1995). Zira gelecekteki herhangi bir durum konusunda bahise girerken kazanma olasılığı 50:50 yani ya A ya da B şeklinde değildir. Eğer sözkonusu durum A olmayacaksa B, C, D, E, ya da F olabilir. Zaten senaryo analizinin getirdiği faydayı arttıran da uzun dönemdeki bu olası gelecek durumlarının çeşitliliğidir.

Gelecek için birçok olası durum vardır ve herhangi birine gitmek için izlenecek yol da her zaman bir tane değildir (Godet, 1994). Bu sözkonusu potansiyel gelecek görüntüsü ve ona ulaşmak için izlenecek yol “senaryo” olarak tanımlanır. Senaryo analizi, organizasyonları çevreleyen uzun vadeli belirsizliklerle etkin bir şekilde başedebilmek için 1970’lerden bu yana artan bir şekilde kullanılmaya başlanmıştır (Bood ve Postma, 1997). Daha önceleri yani 1950 ve 1960’larda birçok şirketin varolduğu endüstriyelmiş ülkelerde çevresel belirsizliğin şimdiye oranla çok daha az olduğu söylenebilir (Raubitschek, 1988). O yıllarda büyüyen bir ekonomi ve yatırımlar için birçok fırsatın varlığının yanı sıra; sosyopolitik güçlerin iş hayatı üzerinde de önemli bir etkileri olmamıştır. Bu dönemde şirketler gelecekle ilgili varsayımlarını geçmiş verileri temel alan tahminlerle yapmışlardır. 1970’lerde şirketleri çevreleyen ortamın değişmeye başlamasıyla; büyük bir belirsizlik ortamının yanı sıra sosyal, politik ve teknolojik unsurlar da en az ekonomik unsurlar kadar şirketlerin işleyişine etki etmeye başlamıştır. Özellikle 1973 ve 1979’daki petrol krizi,

artan globalleşme ve yeni teknoloji gereksinimleri gibi nedenler, birçok şirketin stratejik karar verme süreçlerinde artan bir şekilde senaryo analizlerinden yararlanmaları sonucunu doğurmuştur (Schoemaker, 1993). Royal Dutch/Shell, senaryo düşüncesinin öncü kullanıcı ve yaratıcılarından biridir. Sözkonusu şirket, senaryo analizini 1970'lerde orta kademe yöneticilerini OPEC teşvikli fiyat yükseltme olasılığına hazırlamak için kullanmaya başlamıştır. 1973'te petrol fiyatları dörde katlandığında Shell, senaryo planlarını bu tip krizlere hazır olmak için daha ciddi olarak ele almıştır. Shell, senaryo analizini varılacak son noktanın tanımlanması olarak değil, daha çok dinamik yapıyı ve ilişkiler ile gelecekle ilgili birçok olasılığı ortaya koymak için de kullanmıştır.

Senaryo analizi, geleneksel tahmin tekniklerinden farklı bir yere sahiptir (Bood ve Postma, 1997). Bu tarz analitik teknikler geçmiş verileri kullanarak tahminler üretirler. Oysa gerçek hayat, beklenmedik bir takım değişimler barındırır ve bu tarz değişiklikler de sadece geçmiş verileri temel alan analizleri daha yarattıkları anda bile geçersiz kılabilir. Bu açıdan bakıldığında senaryo analizi, yöneticilere gelecekle ilgili birbirinden farklı bir çok değişik görüntü sunabildiği için çevresel belirsizlikler karşısında daha donanımlı olunmasını sağlar. Zira senaryolar gelecekte olabileceklere dair öyküler ya da "anlık fotoğraflardır" (Wollenberg ve diğ., 2000). Karar vericiler bu birbirinden farklı olası gelecek görüntülerini, şu anda yapılabilecekleri kararlaştırmak için kullanırlar. Ancak bu görüntülerinin gelecekle ilgili en olası görüntüler olması gerekmez (Bunn ve Salo, 1993). Sözkonusu görüntüler gelecekteki herhangi bir durumu yansıtabileceği gibi mevcut durumun beklenen gelişimi göstermesi sonucu varılabilecek noktayı da tanımlayabilir. Senaryolar yardımıyla, yöneticiler karar verirken bir dizi olası gelişmeyi dikkate almış olurlar.

Yapılan araştırmalara göre Fortune 1000'deki şirketlerin yaklaşık olarak yarısı senaryo analizini kullandıklarını belirtmişlerdir. Bir diğer araştırmaya göre ise 1984 yılında Avrupa'daki büyük şirketlerin %36'sı senaryo analizini kullanırken, bu oran 1985 yılında %40'a yükselmiştir. Bu yüzden de senaryo analizinin özellikle petrol şirketleri, taşıt üreticileri ve elektrik tedarikçileri gibi uzun planlama dönemlerine gerek duyan şirketler arasında popüler bir yöntem olduğu söylenebilir.

Senaryo analizinin tipleri ve kullanımında bir çeşitlilik söz konusuysa da; “senaryo” sözcüğü üzerinde farklı tanımlamalarla da olsa hemen hemen bir anlaşma sağlanmıştır. Senaryonun birbirinden farklı birkaç tanımlaması şöyle özetlenebilir. Senaryo;

- Nedensel süreçler ve karar noktaları üzerinde odaklanmayı sağlamak için yaratılmış olayların hipotetik sıralanışıdır.
- Belirli bir organizasyonun ya da grubun tanımlanmış varsayımlar çerçevesinde geliştirilmiş nitel ve nicel verilerden oluşan resmidir .
- Çevredeki birbiriyle ilişkili unsurların olası gelişmelerinin gözönünde tutularak bir organizasyonun çevresinin olası gelecek görüntüsünün tanımlanmasıdır .
- Organizasyonların geleceği “keşfetmek” için kullandıkları bir araçtır (Tenaglia ve Noonan, 1992).
- Zaman içindeki gelişmelerin hipotetik tanımlanmasıdır. Gelecek ile ilgili alternatif varsayımlar sunarken çevredeki bileşenlerin birbirleriyle olan ilişkilerindeki olası değişimleri de yansıtır (Raubitschek, 1988).

Ancak senaryoların gelecekteki belirsizlikleri çözmek için bir araç olmadığı da unutulmamalıdır (Weinstein, 1995). Senaryo analizinde odaklanılan konu, belirsizliği çözmek değil, organizasyonun hedefleri, hedeflerle ilgili kritik başarı faktörlerinin üzerinde yönetim kademesinin etkisi, bu faktörler üzerinde etkisi olan gelecekteki dış çevre özellikleri ve hedeflerin uygunluğu arasındaki ilişkilerdir. Bu süreçteki en önemli nokta “olaylar gelecekte şu şekilde gelişse ne olur?” sorusunun ciddiye alınmasıdır.

Senaryo analizi, planlamadan önce düşünce yeteneğini geliştirmeyi zorunlu kılar ve dış çevreye olan duyarlılığı artırır. Bunun yanı sıra, senaryolar oldukça esnekler (Raubitschek, 1988). Nicel, nitel ya da her ikisinin karması terimlerle ortaya konulabilirler; politik, sosyal, teknolojik ve ekonomik faktörler ile bunların arasındaki ilişkileri bünyelerinde barındırırlar.

Bir organizasyonun hangi durumlarda senaryo analizinden yararlanacağını ortaya konulması zor olsa da;

- Belirsizliğin yüksek olması
- Geçmişte maliyeti yüksek çok sayıda sürpriz yaşanmış olması
- Algılanan ve yaratılan yeni fırsatların yetersizliği
- Stratejik planlamanın çok rutin bir hal alması nedeniyle stratejik düşünmenin kalitesinin düşüklüğü
- İçinde bulunulan endüstrinin önemli değişimler içinde bulunması ya da böyle bir olasılığın varlığı
- Farklılığın yok edilmeden organizasyon bünyesinde ortak bir dil oluşturma isteği
- Herbiri farklı yarara sahip kuvvetli farklılıklar ve görüşlerin varlığı
- Rakiplerin senaryo analizi kullanıyor olması

şeklinde sıralanabilecek nedenler organizasyonların belli başlı senaryo analizi kullanım gerekçeleri olarak ifade edilebilir (Schoemaker, 1991).

1.1 Senaryo Analiz Süreci

Senaryolar karar merkezli olmalıdırlar (Raubitschek, 1988). Bir diğer deyişle, senaryoların oluşturulması değişik karar tipleri için de olsa tek bir seçim sürecini kapsamalıdır. Her durumda, tasarımcı belirsizlik alanlarını ve diğer önemli alanları tam olarak anlayabilmeli; politik, sosyal, teknik, ekonomik ve rekabetsel kritik değişkenleri saptayabilmeli ve bunları karar vermek için yararlı bir çerçeveye oturtmak üzere etkin bir şekilde birkaç senaryo oluşturacak şekilde birleştirebilmelidir.

Analizin farklı aşamaları farklı tip bilgiye, ayrıntıya ve güvenilirliğe sahip olmalıdır. Senaryoların seçimi ve tasarımı için üç temel prensip önerilebilir. Bunlar; güvenilirlik, fayda ve anlaşılabilirliktir. Bu üç kriter birbiriyle ilişkidir ve

senaryoların uygulanabilirliđi úzeinde oldukça etkilidirler. Karar vericiler senaryoları eđer güvenilirlerse; onlara yararlı bilgiye sahiplerse ve anlaşılabilirlerse kullanırlar.

Bunların yanısıra senaryolar oluşturulurken yöneticilerin dünyayla ilgili görüşlerini de temel alan bir senaryonun olması yararlıdır. Zira eđer oluşturulan tüm senaryolar yönetim kademesine yabancı olursa, reddedilmeleri olasıdır.


Godet'e göre (1994) pratikte tek bir senaryo yöntemi yoktur zira bazı yöntemler basit bazıları karmaşık yapıya sahiptirler. Yine de senaryo yöntemi denildiğinde geçilmesi gereken temel aşamalar konusunda genel bir uzlaşma sağlanmıştır. Senaryo analizi süreci öncelikle yaratıcı bir bakış açısı gerektirir ve sahip oldukları temel yapı Şekil 1.1'de ortaya konulana benzer (Bood ve Postma, 1997). Uygulamada senaryoların oluşturulması ardışık bir süreçtir ve birbiriyle ilişkili aşamalar arası gidip gelmeyi gerekli kılar.

Senaryo analizine başlamadan önce müşteriler, tedarikçiler, çalışanlar, analizeciler ile akademisyenlerden meydana gelen ve 6-20 kişi arası deđişen bir grupla bir çalışma düzenlenmesi yararlı olabilir (Schoemaker, 1995). Bu grupla birlikte yapılan çalışma sonucu, içinde bulunulan mevcut durum ve temel belirsizlikler daha etkin bir şekilde ortaya konabilir.

Senaryo geliştirme sürecinin ilk aşaması problemin tanımlanması ile başlar (Bood ve Postma, 1997). Bu aşamada problemin sınırlarının çizilmesi, sürece katılacak kişilerin belirlenmesi ve senaryo çalışmasının zaman kapsamanın oluşturulması yer alır. Zaman kapsamı; teknolojik deđişim hızı, ürün hayat eđrisi, politik seçimler, rakiplerin planlama dönemleri gibi birçok faktöre bađlıdır (Pamuk ve diğ., 1997).

Daha sonra geleceđi daha iyi tanımlayabilmek için mevcut durum analiz edilir (Bood ve Postma, 1997). Bu noktada mevcut durumun detaylı analizi için SWOT tekniđi kullanılabilir. Bu aşamada sistem yaklaşımından yararlanmak zorunludur. Mevcut durum analizi hem nitel hem nicel açıdan ayrıntılı; ekonomik, teknolojik, politik, sosyolojik vb. alanları kapsamalı; hem geçmiş hem de gelecekle bađlantılı yani dinamik olmalı ve deđişimi yaratan mekanizma ve kişileri içermelidir (Godet, 1994). İdealde bir senaryo sosyal, ekonomik, politik ve teknolojik gelişmeleri birbiri içinde tutarlı bir şekilde yansıtan gelecek tanımlaması olduđu için senaryo sürecinin en

önemli aşaması da içinde bulunulan iş çevresinin bileşenlerini ve birbirleriyle ilişkilerini tanımlamaktır (Leemhuis, 1985).




Şekil 1.1 Senaryo Geliştirme Süreci (Bood ve Postma, 1997, s.634)

Üçüncü aşamada gelecekteki gelişmeleri ve gelecekle ilgili “harekete geçiren güçler” ya da “nedensel etkenler” olarak tanımlanabilecek ilgili etkenleri tespit etmek yer alır (Bood ve Postma, 1997). Bu etkenler sabit, tahmin edilebilen ve belirsizlikler olmak üzere sınıflandırılmalıdır. Sabit etkenler kaynaklar, aktörler, kurumlar, olaylar ve bunlar arasındaki ilişkilerdir (Wollenberg ve diğ., 2000). Tahmin edilebilen etkenler ise nüfus artışı, gibi sabit olmasa da değişimi yavaş olduğundan önceden kestirilebilen değişkenlerdir. Belirsizlikler ise değişimi tetikleyen asıl etkenlerdir. Bu sınıflandırma senaryo süreci için çok önemlidir. Zira, sabit ve önceden tahmin edilebilen etkenler her bir senaryo için aynıken; belirsizlikler senaryolar arası farklılıkların oluşmasına yolaçarlar (Bood ve Postma, 1997). Temel belirsizliklerin sınıflandırılması ile ise birbirinden farklı değişik senaryolar ortaya çıkmış olur.

Bu aşamada çok sayıda olabilecek etkenlerin analize olanak tanıyacak bir miktara indirgenmesi problemi ile karşılaşılabilir. Bu problemi ortadan kaldırmak için Godet (1991) tarafından bir yöntem önerilmektedir. MICMAC (Matrice d’Impacts Croisés-Multiplication Appliquée a un Classement / Cross Impact Matrix-Multiplication Applied to Classification) olarak adlandırılan yöntemin izlediği süreç; uzmanlardan

alınan görüşlerin, yönlü çizgeler yardımı ile ortaya konması ile başlamaktadır. Bölüm 3’de ayrıntıları ile anlatılacak olan Bilişsel Haritalara benzer şekilde oluşturulan bu çizgelerden; değişkenler arası direkt ilişkileri gösteren komşuluk matrislerine geçiş yapılmaktadır. Konu ile ilgili ilk bilgi; komşuluk matrisinin içerdiği bu direkt ilişkilerden ortaya çıkar: i.satırın toplamı, i değişkenin etkilediği; j.sütunun toplamı ise, j değişkenin etkilendiği değişken sayısını vermektedir (Ayrıntılar Bölüm 3’de verilmektedir). Satır ve sütun toplamlarına bakıldığında en yüksek değerlere sahip olanlar konu ile ilgili en önemli değişkenler olarak adlandırılabilirler.

Ancak direkt ilişkileri gösteren komşuluk matrisi sadece 1 uzunluğundaki yolları göstermekte; değişkenler arası dolaylı ilişkiler hakkında bilgi vermemektedir. Oysa; matrisin karesi alındığında; ikinci-dereceden ilişkiler ortaya konulabilir. Benzer şekilde matrisin n.dereceden üssü alındığında n uzunluğundaki yollara sahip dolaylı ilişkiler hakkında bilgi sahibi olunacaktır. Matrisin her dereceden üssünün alınması ile farklı bir “en çok etkileyen ve etkilenen değişken” sıralaması olacaktır. Ancak bu sıra, belirli bir üs derecesinden sonra (genellikle 7 veya 8) bir dengeye oturacaktır. MICMAC, bir örnek ile daha açık hale getirilebilir. Aşağıdaki gibi bir yönlü çizgeye ve ilgili komşuluk matrisine sahip olunsun.



Matrisin karesi alındığında uzunluğu 2 olan yollara sahip dolaylı ilişkiler ortaya konulabilecektir.

$M^2 =$

	A	B	C	Σ
A	1	0	1	2
B	1	1	0	2
C	0	1	0	1
Σ	2	2	1	

Benzer şekilde matrisin 3., 4., 5. ve 6. dereceden üsleri alındığında da ilgili uzunluktaki yollar belirlenebilir.

$$M^3 =$$

	A	B	C	Σ
A	1	1	0	2
B	1	1	1	3
C	1	0	1	2
Σ	3	2	2	

$$M^4 =$$

	A	B	C	Σ
A	1	1	1	3
B	2	1	1	4
C	1	1	0	2
Σ	4	3	2	

$$M^5 =$$

	A	B	C	Σ
A	2	1	1	4
B	2	2	1	5
C	1	1	1	3
Σ	5	4	3	

$$M^6 =$$

	A	B	C	Σ
A	2	2	1	5
B	3	2	2	7
C	2	1	1	4
Σ	7	5	4	

Matrislerin ortaya koyduğu sıralamanın 4.dereceden üssün alınması ile dengeye oturduğu görülmektedir. Sıralamaya göre diğer değişkenleri en çok etkileyen değişken B iken; diğer değişkenlerden en çok etkilenenin A olduğu söylenebilir. Çok sayıda değişkenin bulunduğu durumlarda MICMAC, değişkenler arasında bir önem sıralaması yarattığından oldukça yarar sağlayabilir.

Bu aşamalardan sonra senaryoların yapılandırılması gereklidir. Burada önemli olan senaryoların kendi içlerinde tutarlı ve anlaşılır olmalarıdır. En olası, en iyi ya da en kötü gelecek görüntülerini yansıtmaları beklenmez. Zaten belirsiz bir gelecek için bu tür adlandırmalar yapmak da çok doğru kabul edilmez. Bu aşamada, yani senaryolar oluşturulurken istenmeyen senaryoların yaratılmasına ek bir zaman ayırmak faydalı olur (Bunn ve Salo, 1993). Zira insanlar genelde umutları ile çelişen delilleri dikkate almama eğilimindedirler. Benzer şekilde de istedikleri olayların oluşma olasılıklarının diğerlerine göre daha yüksek olduğuna inanırlar. Yöneticiler de onlara zarar verebilecek durumlar için planlama yapmaktan genelde rahatsızlık duyarlar. Bu yüzden en azından bazı senaryolar kötü çıktılarının da hakettikleri dikkati alabilmeleri için olası tehlikeleri ortaya koyabilmelidir.

Bunun yanı sıra senaryolar geleceği iki farklı şekilde ortaya koyabileceğinden, hangi tarzda bir senaryo yaklaşımı izleneceğine karar verilmelidir. Zira senaryolar, gelecekteki herhangi bir andaki görüntüyü ortaya koyabileceği gibi buna alternatif olarak gelecekteki herhangi bir zamana kadar geçen süredeki olası gelişmeleri de evrimsel şekilde bünyesinde barındırabilirler (Becker,1983).

Bundan sonra senaryolar artık kullanıma hazır hale gelirler. Yöneticilerin yüzyüze oldukları problemlerle başa çıkmak ve karar vermelerine yardımcı olmak amacıyla analize ve yorumlanmaya açıktırlar.

Son olarak stratejik karar verme sürecinin senaryolarla desteklenmesinden bahsedilebilir. Bu aşama her senaryo analizinde birbirinden farklı olabilir çünkü senaryoların stratejik karar verme süreci içindeki kullanım şekilleri değişiklik gösterebilir (Bood ve Postma, 1997). Yine bu aşamada senaryoların kullanımı tek tek kişilerin bireysel çalışmaları ile olabileceği gibi ekiplerin takım çalışması ile de yapılabilir.

Schoemaker'a (1993) göre ise senaryo süreci 10 temel adımdan meydana gelir.

1. Daha iyi anlaşılması istenen kavramların dikkate alınacak zaman dilimi, çalışmanın kapsamı ve karar değişkenleri gözönünde bulundurularak tanımlanması. Bu adımda belirsizlik ve geçicilikle ilgili fikir sahibi olmak için geçmiş verilerden yararlanmak faydalı olabilir. Bunun yanı sıra, dikkate alınacak zaman diliminin belirlenmesinin teknolojinin değişim hızı, ürün ömür süreleri, rakiplerin planlama periyotları gibi birden çok faktöre bağlı olduğu unutulmamalıdır (Schoemaker, 1995).
2. Bu kavramlarla ilgili olan temel aktörlerin belirlenmesi (Schoemaker, 1993). Bu adımda hem kavramları etkileyen hem de sözkonusu kavramlardan etkilenenler dikkate alınmalıdır. Ayrıca bu aktörlerin mevcut durumlarının, konuyla bağlantılarının ve konumlarının onlara sağladığı güçler de tanımlanmalıdır. Genellikle en belirgin aktörler müşteriler, tedarikçiler, rakipler, çalışanlar, hissedarlar ve devlet'tir (Pamuk ve diğ., 1997).
3. İlgilenilen değişkenleri etkileyen mevcut eğilimlerin (ekonomik, politik, teknolojik, çevresel ve sosyal) listesinin yapılması (Schoemaker, 1993). Her bir değişken açık bir şekilde tanımlanmalı, neden ve nasıl bir etki yarattıkları üzerinde durulmalıdır. Bu aşamada diyagramlardan yararlanmak değişkenler arası ilişkileri göstermek için yararlı olabilir.
4. Çözümleri ilgilenilen değişkenleri olumlu ya da olumsuz bir şekilde ama mutlaka önemli bir düzeyde etkileyebilecek temel belirsizliklerin

tanımlanması. Sözkonusu belirsizliklerin neden önemli olduğunu ve incelenen konuyla ilişkileri açık bir şekilde ortaya konmalıdır. Bunun yanısıra herbir değişkenin yaratacağı olası çıktı da ortaya konmalıdır (Schoemaker, 1995).

5. İki adet senaryonun hazırlanması. Sözkonusu senaryolardan biri belirsizlerden kaynaklanan tüm olumlu çıktıları bir diğeri de tüm olumsuz çıktıları kapsamalıdır (Schoemaker, 1993).
6. Bu yapay senaryoların iç tutarlılık ve olabilirliklerinin belirtilmesi. Sadece olumlu ya da sadece olumsuz çıktılar büyük olasılıkla tutarsızlığa neden olabilir. Bu yüzden sözkonusu senaryoların nerelerde ve neden tutarsız olabileceklerinin ortaya konması gereklidir. Bunun için ilk olarak daha önce ortaya konmuş olan eğilimlerin çalışılan zaman dilimi ile tutarlılık içinde olup olmadığının araştırılması gereklidir (Schoemaker, 1995). Ayrıca, aynı senaryo içinde bulunan çıktı çiftlerinin birbirleriyle tutarlılığı da incelenmelidir. Bu aşamada dikkat edilmesi gereken bir üçüncü nokta ise temel aktörlerden bazılarının beğenmeyip değiştirmek isteyebilecekleri konumlarda olup olmadığının araştırılmasıdır (Pamuk ve diğ., 1997). Örneğin OPEC önemli bir aktörse, sözkonusu aktör uzun süre petrol fiyatlarını düşük tutma politikasını sürdürmeyecek ve buna bağlı olarak oluşturulan senaryo yerini bir başka senaryoya bırakabilecektir. Bu nedenle daha kararlı yapıda senaryoların oluşturulması gereklidir.
7. Değersiz ya da imkansız bileşimlerin elenmesi ve tutarlılık sağlanıncaya dek en az iki adet yeni senaryonun üretilmesi (Schoemaker, 1993). Yeni senaryoların geniş bir çıktı yelpazesine sahip olmasına dikkat edilmelidir.
8. İkinci aşamada tanımlanan anahtar kişilerin sözkonusu senaryolarda nasıl davranacaklarının değerlendirilmesi. Böylece bu kişilerin davranış farklılıklarının senaryolarda ne gibi değişikliklere yol açabileceği belirlenebilir.
9. Senaryoların iç tutarlılığının yeniden gözden geçirilmesi ve belirli bazı ilişkilerin nicel (kantitatif) bir model şeklinde formüle edilip edilemeyeceğinin belirlenmesi gereklidir. Eğer formüle edilebiliyorsa,

sözkonusu model, değişkenler için belirsizlik sınırları ya da genel dağılımları belirlendikten sonra Monte Carlo simülasyonu çalıştırılmak için kullanılmalıdır.

10. Son olarak, senaryoların stratejilerin oluşturulması, test edilmesi ve yeni fikirler oluşturulması için kullanıma geçirilmesinin gerçekleştirilmesi gereklidir (Schoemaker, 1995).

1.2 Senaryo Analiz Yaklaşımları

Senaryo analizinin gelişmesiyle birlikte kullanılabilecek farklı yaklaşımlar ortaya çıkmıştır (Huss ve Honton, 1987). Bu yaklaşımlar temel olarak üç sınıfta toplanabilirler.

1.2.1 Sezgisel Mantık

Senaryo analizi yaklaşımı olarak sezgisel mantık yaklaşımını kullanan şirketlere örnek olarak hizmet sektöründen SRI International, üretim sektöründen ise Dutch/Shell verilebilir. Sezgisel mantık yaklaşımı işle ilgili kararların ekonomik, politik, sosyal ve çevresel faktörler arasındaki karmaşık ilişkilere dayandığı varsayımını temel alır. Bu faktörlerin birçoğu şirketler için dış çevre faktörleridir ve ürün gelişimi, yeni yatırımlar, kapasite artımı, yeni teknoloji ile ilgili kararların verilmesi için iyi bir şekilde anlaşılmaları gereklidir. Bunlardan bazıları demografik özellikler gibi, açık, nicel ve belirli bir dereceye kadar tahmin edilebilir iken bazıları müşteri davranışları gibi, daha az kesinliğe sahip, nitel ve tahmin edilemezlerdir. Bu yaklaşımın yararı esnek ve iç tutarlılığa sahip senaryolar üretilebilmesidir. Herhangi bir matematiksel algoritma içermediğinden dikkatli bir çalışma ile şirketin özel gereksinimlerine ve politik çevresine uyum sağlayacak senaryolar üretilebilir.

Sözkonusu senaryo analiz yaklaşımının sekiz temel adımı vardır.

1. adım: Kararlar ve stratejilerle ilgili kavramların analizi

İlk adım sermaye dağılımı, yatırımlar ve pazar stratejileri gibi şirketin uzun dönem kararları üzerine yoğunlaşılmasını sağlamak için analizin sahasının genişliğinin ortaya konulmasını gerektirir. Analiz sahasının daraltılması senaryo geliştirilmesini kolaylaştıran bir etki yaratır. Bu yüzden bu aşamada ilgilenilecek kavramların tam

olarak belirlenebilmesi için ilgili yönetim kademesi ve çalışanlarla yakın bir çalışma gereklidir.

Senaryo sürecinde üzerinde odaklanılacak konusunun saptanması planlama gereksinimlerinin daha iyi algılanmasını ve daha etkin stratejik kararlar alınmasını sağlayacağından oldukça önemlidir (Morrison ve Wilson, 1997). Dar kapsamlı odaklanma evrensel ekonomi ya da toplumsal gelecek gibi geniş kapsamlı konuların atlanması sonucunu doğurur. Oysa senaryolar yardımıyla odaklanılan konuların taktik değil stratejik olması; senaryo sürecinin doğasında vardır. Zira senaryo analizi kısa dönemli beklentiler yerine uzun dönemdeki belirsizlikler ve eğilimler ile ilgilidir. Bu yüzden üzerinde çalışılacak konunun ve konu ile ilgili kavramların net bir şekilde ortaya konması gereklidir.

Bu aşamada içinde bulunulan durumu ve ilgili kavramları daha etkin bir şekilde ortaya koyabilmek için SWOT analiz tekniğinden yararlanmak iyi bir başlangıç noktası oluşturabilir (Bood ve Postma, 1997).

2. adım: Temel karar faktörlerinin belirlenmesi

Konu belirlendikten sonra her bir kararın çıktılarını etkileyen temel faktörlerin belirlenmesi gereklidir (Huss ve Honton, 1987). Bu faktörler pazar boyutu, ekonomik koşullar, fiyat eğilimleri, insan, malzeme ve enerji kaynakları ile ilgili olabilir. Bu faktörlerle ilgili ne kadar çok şey bilinirse, verilecek kararların kalitesi de o kadar artar.

Karar faktörleri ile ilgili en önemli unsur, sözkonusu faktörlerin genellikle çevresel ve büyük ölçüde kontrol dışı olmalarıdır (Morrison ve Wilson, 1997). Bu, temel karar faktörlerinin içinde hiç kontrol edilebilir ve içsel değişken olmayacağı anlamına gelmese de genellikle organizasyon yapısı gibi kontrol edilebilir ve içsel değişkenlerin planlama sürecinde senaryo analizi kapsamında daha az yer almaları sonucunu doğurur, çünkü senaryo analizi belirsizliklerle başa çıkmak için kullanılan bir strateji belirleme aracıdır ve sözkonusu belirsizlikleri de büyük ölçüde kontrol dışı faktörler oluşturur.

Karar faktörlerinin belirlenmesi aşamasında bilişsel haritalar yaklaşımından yararlanılabilir. Böylece uzman yargısının edinildiği kişilerden etkin bir şekilde bilgi

sağlanması gerçekleştirilmiş olduğu gibi bunun yanısıra sözkonusu karar faktörleri arasındaki ilişkiler de ortaya konmuş olur.

3. adım: Temel çevresel güçlerin belirlenmesi

Çevresel güçler temel karar faktörlerinin durumunu belirledikleri için önemlidirler (Huss ve Honton, 1987). Sosyal, ekonomik, politik ya da teknolojik olabilirler. Demografik yapıları, sosyal ve hayat tarzı faktörlerini, ekonomik durumları, ekosistemi, teknolojik faktörleri, doğal kaynakları kapsayabilirler.

Çevresel güçler ortaya konurken bazı soruların yanıtları aranır (Morrison ve Wilson, 1997):

- Mevcut durumda çevresel güçlerle ilgili temel eğilimler ve belirsizlikler nelerdir?
- Bu güçlerin birbirleriyle olan ilişkileri nasıldır?
- En önemli olarak niteledirilebilecek olanlar hangileridir?

4. adım: Çevresel güçlerin analizi

Bu aşamada her bir çevresel gücün tarihsel yapısı, izlediği eğilimler, kritik belirsizlikleri ve diğer çevresel güçler ile ilişkileri ortaya konulmalıdır (Huss ve Honton, 1987). Bu analizler senaryoları sürprizlere meydan vermeyecek şekilde donanımlı ve esnek kılınabilecek kadar ayrıntılı olmalıdır.

5. adım: Senaryo mantığının tanımlanması

Senaryo mantığının tanımlanması, bu yaklaşımın temel gücü ve onu diğer yaklaşımlardan ayıran belirleyici özelliğidir. Senaryo mantıkları onları tutarlı, uygun ve esnek kılan prensip, tema ve varsayımlardır. Daha önceki adımlarda ortaya konan belirsizlik ve koşulların birçoğunu bünyelerinde barındırmalıdırlar. Bunun yanısıra fırsat ve tehditleri de kapsamalıdırlar.

6. adım: Senaryoların ayrıntılandırılması

Bu aşama, senaryo mantıklarının çevresel analizlerle birleştirilmesidir. Böylece kararlar için önemli olan temel faktörlerle ilgili bilgiye odaklanılması sağlanır.

7. adım: Temel karar faktörleri ile ilgili analizin yapılması

Bu adımda, ikinci adımda belirlenen temel karar faktörleri ile ilgili her bir senaryonun ne içerdiğinin belirlenmesine odaklanılır. Bu adımın en önemli bölümü, senaryolarla sunulan bilginin karar vericiler için açık ve net olmasının sağlanmasıdır zira ayrıntılı analizler genellikle bu aşamadan sonra yapılır.

8. adım: Karar ve stratejiler ile ilgili analizin yapılması

Bu son aşamada bir dizi soruya yanıt aranır.

- Stratejiler ve önerilen kararlarla ilgili varsayımlar ortaya konan gelecek görüntüleri ile destekleniyor mu?
- Senaryolar stratejilerin tasarımı ve zamanlaması ile ilgili olarak ne ortaya koyuyor?
- Senaryolar hangi fırsat ya da tehditleri öneriyor?
- Senaryolardan hangi kritik kavramlar ortaya çıkıyor?
- Özel olarak planlamayı gerektiren durumlar hangileri?
- Şirketin planlama yaklaşımı açısından senaryoların önerdiği esnekliklerden hangileri gerekli?
- Senaryolar ışığında hangi güçler ve etkenler özel olarak izlenmeyi gerektiriyor?

1.2.2 Eğilim-Etki Analizi (Trend-Impact Analysis)

Bu yaklaşım 1970'lerde birçok şirket tarafından denenmiştir. Eğilim-etki analizi, konu ile ilgili temel bağımlı değişkenler hakkında yapılan tahminlere dayanır. Bu tahminler daha sonra etkileyecekleri olayların gerçekleşmesine bağlı olarak değişime uğrarlar. Bu yöntem geleneksel tahmin teknikleri ile nitel faktörler arasında bir köprü kurar (Bunn ve Salo, 1993). Çok basit olarak, genel eğilimi etkileyebilecek özel olayların dikkate alınması için istatistik bir tahmin modeli ve bir dizi olası yargı ile uğraşılması gerektiği söylenebilir. Bu yaklaşımın en önemli dezavantajı, olayların gerçekleşme olasılıkları gibi, yüksek güvenilirlikleri olmayan bir çok girdiye sahip

olmasıdır. Bunun yanı sıra, izlenen süreç, kullanıcıya, belirsizliklerin ortadan kalktığı gibi bir izlenim verir. Oysa yapılan, çok da güvenilir olmayan girdiler aracılığıyla güvenilirlikleri yüksek olmayan tahminler gerçekleştirmektir.

Bu yaklaşımın da 8 adımı vardır (Huss ve Honton, 1987). Bunlar;

1. Konunun ve temel senaryo güdüleyicilerinin (driver) belirlenmesi

Tüm yaklaşımlarda olduğu gibi ilk adım konunun belirlenmesidir. Daha sonra karar verme ile ilgili faktörlerin ortaya konması için iki ya da üç senaryo itkisinin seçilmesi gereklidir. Bir itki, GSMH (yüksek, orta, düşük) iken bir diğeri yasal düzenlemeler (gevşek, sıkı) olabilir ki bu iki itkinin bir matriste ortaya konması ile 6 adet senaryo oluşturulabilir.

2. Senaryo uzayı yaratılması

İlk adımda belirlenen altı adet senaryodan bir alt küme seçilir. Seçilen üç senaryodan biri düşük GSMH, sıkı yasal düzenlemeler; bir diğeri orta GSMH, gevşek yasal düzenlemeler; sonuncusu ise yüksek GSMH, gevşek yasal düzenlemeler olabilir. Bundan sonraki aşamalar bu üç senaryodan herbiri için yapılır.

Bu aşamada senaryo uzayından seçilecek alt kümenin barındıracağı senaryo sayısı tamamen kullanıcıya bağlıdır (Becker, 1983). Senaryo uzayının eksenlerinin bölünmesi ile ortaya çıkan senaryoların hepsi dikkate alınabileceği gibi sadece iki tanesi de seçilebilir. Analiz için seçilen her bir yeni senaryonun ek zaman ve kaynağa gereksinim duyacağı gözönünde bulundurulmalıdır. Genelde en çok tahmin edilenin yanı sıra bir iyi bir de kötü örnek olması en çok kullanılan yöntemdir.

3. Önemli eğilimlerin belirlenmesi ve zaman serisi verilerinin toplanması

Sözkonusu senaryoları etkileyen eğilimlerin bir listesinin çıkarılması ve bir sonraki adım için de herbirinin verisinin toplanması gereklidir (Huss ve Honton, 1987).

4. Basit bir tahmin hazırlanması

Standart zaman serisi tekniklerinin yardımı ile tahminler gerçekleştirilir.

5. Etkileyen olayların bir listesinin oluşturulması

Üçüncü adımda belirlenen ve daha sonra da tahmin edilen eğilimleri etkileyen olayların listelenmesi Delphi tekniği yardımı ile ya da literatür taraması ile ortaya konulabilir. Bu olaylar, sezgisel mantık yaklaşımındaki çevresel güçlerle ayırdırılar ve sosyal, politik, ekonomik ya da teknolojik olabilirler.

6. Olayların gerçekleşme olasılıklarının tahmin edilmesi

Sözkonusu olayların gerçekleşme olasılıklarının tahmin edilmesi gereklidir. Olayların gerçekleşme olasılıklarının yanısıra yaratacakları etkilerin büyüklüklerinin ve sürekliliklerinin de tahmin edilmesi yararlı olacaktır (Bunn ve Salo, 1993). Bunun yanısıra olaylar arasındaki geçen zaman ile ilk ve en büyük etkileri de ortaya konmalıdır.

7. Dördüncü adımda gerçekleştirilen tahminin düzeltilmesi

Bu aşamaya kadar elde edilen parametreler, ekstrapolasyonun düzeltilmesi için birleştirilir ve daha önce yapılan tahmin yeni veriler ışığında düzeltilir. (Huss ve Honton, 1987).

8. Senaryoların yazılması

Son aşamada her bir eğilim-etki analizinin sonucu uyarınca ilgili senaryoların yazılması gerçekleştirilir.

Eğilim-etki analizi için kullanılabilecek paket programlarından biri Bonnicksen (1992) tarafından geliştirilen EZ-Impact'dir. Sözkonusu paket program, sistem düşüncesi yaklaşımı ile büyük sistemlerin pilot modellerinin oluşturulması ve önceden belirlenen hedeflere ulaşılabilirliğin tespitini amaçlayan bir araçtır. Strateji planlama, etkilerin değerlendirilmesi, sistem düşüncesinin öğretimi, sistem ilişkilerinin anlaşılması, politikaların sonuçlarının takibi ve değerlendirilmesi gibi hedefleri olan EZ-Impact, uzman yargısına dayalı bir bilgisayar programıdır. Mevcut durum dahil 6 farklı durumun incelenmesine, her bir değişken için 8 alternatif hedef belirlenmesine olanak tanır. İncelenen konu ile ilgili değişkenler programa verildikten sonra, program her bir değişkenle ilgili eğilimlerin (ki bunu sözkonusu değişkende beklenen en fazla artış yüzdesi, ortalama değişim yüzdesi ve dış etkinin yüzdesi olarak ortaya koyar) de girilmesini ister. Ayrıca modeldeki değişkenlerin kendi aralarında da ilişkili olup olmadıklarının tespiti için program, bir çapraz-etki

matrisinin de doldurulmasını kullanıcıdan talep eder. İlgili veriler programa girildikten sonra ise, herhangi bir değişkende kullanıcı tarafından meydana getirilen bir değişikliğin diğer tüm değişkenlerde ve hedef değerlerde ne tür değişikliklere yol açtığını görmek, paket program yardımıyla olanaklı bir duruma gelir.

1.2.3 Çapraz-Etki Analizi (Cross-Impact Analysis)

Bazı tahminçiler, bir olayı diğer temel etki eden olayların ortaya çıkmasından bağımsız şekilde izole edilmiş bir ortamda ele almanın gerçekçi olmadığını ileri sürerler. Çapraz-etki analizi bu eksikliği gidermek gereksiniminden doğmuştur. Bu yaklaşım senaryo geliştirilmesinde dikkate alınan olayların birbirine bağımlılıklarını da analize dahil eder (Bunn ve Salo, 1993). Süreçte, olayların diğer olayları etkileme olasılıkları belirlenir. Bu açıdan nedensel olaylarla ilgili uzman bilgisinin olasılık dağılımlarına dönüştürülmesi gereklidir ve bu, özellikle de uzmanlar olasılıklı düşünme yeteneğine sahip değillerse problem yaratabilir.

İzlenen süreç eğilim-etki analizine benzer ancak olayların eğilimler üzerindeki etkilerinin yanısıra sürecin son aşamasında olayların olaylar üzerindeki çapraz etkisi de dikkate alınır (Huss ve Honton, 1987). Bu yüzden de çapraz-etki analizi, eğilim-etki analizinin daha geliştirilmiş halidir denilebilir. Ancak çapraz-etki analizi için izlenebilecek tek bir yöntem yoktur (Schnaars, 1987). Yine de genelde bu yaklaşımda kullanılan tüm teknikler aynı felsefe üzerine kuruludur. Temel felsefesi hiçbir olayın izolasyon içinde gerçekleşmeyeceğidir. Bunun yerine herbir olayın az ya da çok diğer olayların gerçekleşmelerine bağlı olarak oluştuğuna inanılır. Söz konusu analiz de işte bu “çapraz-etki”leri uzman yargılarından edinmeye çalışır. Daha sonra ise bir olayın başka bir olaya bağlı olarak gerçekleşme olasılığı üzerinde durulur. Elde edilen veriler bir bilgisayar simülasyonu ya da matematik programlama yardımı ile değerlendirilir. Sonuçta ya olması en muhtemel bir senaryo elde edilir ya da birden çok senaryo gerçekleşme olasılıklarına göre sıralanabilir.

Çapraz etki analiz teknikleri içerdikleri tahmin detayına bağlı olarak üç grupta toplanabilir (Bunn ve Salo, 1993). İlk grupta belirlenen zaman dilimi sonunda hangi olayların gerçekleşebileceğini tahmin eden modeller yer alır ki bu yaklaşım dahilinde en çok kullanılan teknik budur. İkinci grupta olayların gerçekleşme sıralarının

tahmini de yer alır. Son olarak üçüncü grupta ise olayların gerçekleşeceği zaman da tahmin edilir.

Çapraz etki analizinin en çok bilinen iki paket programından ilki Center for Futures Research tarafından geliştirilen INTERAX; diğeri ise Battelle Columbus Division tarafından ortaya konan BASICS'tir (Huss ve Honton, 1987).

INTERAX, sekiz adımdan oluşur:

- i. Çalışmanın konusunun ve zaman diliminin belirlenmesi
- ii. Temel göstergelerin belirlenmesi
- iii. Temel göstergelerin tahmin edilmesi
- iv. Etkileyen olayların belirlenmesi
- v. Olay olasılık dağılımlarının geliştirilmesi
- vi. Eğilimler gözönünde tutularak olayların etkilerinin tahmin edilmesi
- vii. Çapraz etki analizinin tamamlanması
- viii. Modelin çalıştırılması

Yöntemin ilk adımı tüm senaryo yöntemlerindeki gibi benzer. Zaman diliminin ve çalışılacak konunun tanımlanması öncelikle gereklidir. Daha sonra "sistemin herhangi bir zaman diliminde ölçülebilen, sayılabilen ya da tahmin edilebilen özellikleri" olarak tanımlanabilecek temel göstergeler belirlenir. INTERAX yaklaşımının üçüncü adımında geçmiş ve mevcut zaman verilerine bağlı göstergelerin tahmin edileceği bağımsız modellerin geliştirilmesi gereklidir. Bu amaçla ekonometrik modeller ile zaman serisi modelleri kullanılır. Dördüncü adımda, literatür taraması, görüşmeler ve grup çalışmaları yardımıyla bir ya da daha çok göstergeyi etkileyebilecek olası gelecek olayların belirlenmesi vardır. Beşinci adımda, kullanıcı zaman dilimini küçük parçalara bölmeli ve uzman yargısı yardımıyla herbir olayın birikimli gerçekleşme olasılıkları tahmin edilmelidir. Bir sonraki adımda herbir olayın her bir gösterge üzerindeki etkisi tahmin edilmelidir. Yedinci adıma olayların olaylar üzerindeki çapraz-etkileri ile olayların eğilimler üzerindeki eğilim-etkileri tahmin edilmelidir. Son olarak ise simülasyon modeli çalıştırılmalıdır. İlk zaman dilimi için model, rassal olarak gerçekleşebilecek olayları

seçer. Olaylar gerçekleştikçe, bu gerçekleştirmeler hem gösterge değerlerini hem de diğer olayların gerçekleştirmelerini etkiler. Bu süreç her bir küçük zaman dilimindeki olayların temel göstergeler üzerindeki etkileri tamamlanıncaya kadar sürdürülür. Modelin her çalıştırılmasında bir senaryo ortaya konur. Birden çok çalıştırılma sonucunda temel göstergeler için bir dizi olası gelecek durum ortaya konmuş olur.

Diğer bir paket program olan BASICS, INTERAX'dan Monte-Carlo simülasyonu kullanmaması yani ilk zaman dilimdeki olayların gerçekleştirmelerini rassal olarak atamaması ile ve temel göstergeler için bağımsız tahmin modellerine gereksinim duymaması ile ayrılır. Göstergeler için tahmin modelleri oluşturmak yerine yöntemde, göstergeler, nicel ya da nitel, birbirinden ayrı tanımlayıcı durumlara bölünür. (örneğin, kadın tüketiciler için, içinde bulundukları yaşa göre bir bölümlendirme yapılabilir.) Yöntem, Monte Carlo simülasyonu yerine ise bir başlangıç durum kümesinin tanımlaması yöntemini kullanır. Başlangıç durumu, bir göstergenin gerçekleşme ya da gerçekleşmeme olasılıklarından biridir. Böylece eğer 10 temel gösterge var ve her bir gösterge için de 3 ayrı durum söz konusuysa $10 \times 3 \times 2$ olası başlangıç durumu var demektir. BASICS, söz konusu tüm bu başlangıç durumları için simülasyon modelini çalıştırır ve toplamda en çok gerçekleşen senaryoları ortaya koyar.

Alarcon ve Ashley, (1998) çapraz etki analizinin sürecini Şekil 1.2'deki gibi ortaya koymuşlardır.



Şekil 1.2 Çapraz Etki Analizi için Süreç Önerisi (Alarcon ve Ashley, 1998, s.146)

Benzer bir süreç önerisinde bulunan Godet ve Duperrin (1991) ise SMIC (“Çapraz Etki Sistemleri ve Matrisleri” tanımının Fransızca karşılığı) olarak adlandırdıkları bir yöntem ortaya koymuşlardır. Yöntemin temel hipotezi; “olayların oluşma olasılıkları eksik bilgidir. Olayların birbirine olan bağımlılıklarının ortaya konması bu eksik bilgiyi tamamlar” şeklinde tanımlanabilir.

Söz konusu yönteme göre, birlikte çalışılan uzmanlardan N adet olay için:

$P(i)$: i.olayın oluşma olasılığı

$P(i/j)$: j.olay oluştuğunda i.olayın oluşma koşullu olasılığı; ve

$P(i/-j)$: j.olay oluşmadığında i.olayın oluşma koşullu olasılığı ile ilgili değerleri istenir.

N olay. için 2^N adet farklı durum ortaya konulabileceği açıktır. “k.” durumun (E_k); π_k gibi bir oluşma olasılığı bulunmaktadır. Uzmanlardan alınan olasılık bilgileri, söz konusu bu 2^N durum için aşağıdaki koşulları sağlayacak şekilde düzenlenir.

(1) $h(i)$: i.olayın oluşma olasılığı;

$\theta_{ik}=0$; i.olay ilgili E_k durumunda oluşmaz ise

$\theta_{ik}=1$; i.olay ilgili E_k durumunda oluşur ise

değerlerini almak üzere; aşağıdaki gibi ifade edilmelidir.

$$P^* = \sum_k \theta_{ik} \pi_k \quad (1.1)$$

(2) j.olay gerçekleştiğinde i.olayın gerçekleşme olasılığı;

$T_{ijk}=0$ i; E_k ’da i.ve j. olaylar birlikte oluşmaz ise

$T_{ijk}=1$; E_k ’da i.ve j. olaylar birlikte oluşur ise

değerlerini almak üzere; aşağıdaki gibi ifade edilmelidir.

$$P^*(i/j) = \frac{\sum_{k=1}^{2^N} T(ijk)\pi_k}{P^*(j)} \quad (1.2)$$

(3) j.olay gerçekleşmediğinde i.olayın gerçekleşme olasılığı;

$S_{ijk} = 0$ i; E_k 'da i.olay oluşurken, j.olayın oluşmaması söz konusu değil ise

$S_{ijk} = 1$; E_k 'da i.olay oluşurken, j.olayın oluşmaması söz konusu ise

değerlerini almak üzere; aşağıdaki gibi ifade edilmelidir.

$$P^*(i/\neg j) = \frac{\sum_{k=1}^{2^N} S_{ijk}\pi_k}{1 - P^*(j)} \quad (1.3)$$

Burada amaç, uzmanlardan alınan olasılık bilgileri ile; yukarıda ifade edilen olasılıklar arasında çok fark olmamasıdır. Bunun için gerekli $(\pi_1, \pi_2, \dots, \pi_k, \dots, \pi_{2^N})$ olasılıklarının bulunması aşağıdaki gibi ifade edilebilecek bir enküçükleme problemi olarak düşünülmelidir.

$$Enkz = \sum_i (P(i) - \sum_{k=1}^{2^N} \theta(ik)\pi_k)^2 + \sum_{ij} (P(i/j)P(j) - \sum_{k=1}^{2^N} T(ijk)\pi_k)^2 + \sum_{ij} (P(i/\neg j)P(j) - \sum_{k=1}^{2^N} S(ijk)\pi_k)^2 \quad (1.4)$$

St.

$$\sum \pi_k = 1 \quad (1.5)$$

$$\pi_k \geq 0; \forall_k$$

Bu aşamada; çözümde yer alabilecek çok sayıdaki π_k 'lar için; "en olası senaryo en yüksek π_k değerine sahip olandır" şeklinde bir seçim ölçütü kullanılabilir. Problem doğrusal kısıtlı bir doğrusal programlama modeli olarak simpleks algoritma ile çözülebilir.

Böylece 2^N durum arasından en yüksek oluşma olasılığına sahip senaryolar; birbiri ile etkileşim içinde olan olaylar da gözönüne alınarak ortaya konmuş olur.

1.3 Senaryoların Fonksiyonları

Senaryo analizinin temelde iki amacı vardır. Bunlardan ilki karar vermeye hazırlık için çevreyi tahmin etmek; ikincisi ise stratejik seçenekleri değerlendirmektir. Senaryo analizini ilk amaçla sınırlı tutmak, onu tahmin konusunun bir alt başlığı yapar. Oysa ikinci amaç gözönünde tutulursa senaryoların yöneticilere karar ve politikalarının farklı hipotetik durumlar altında test edilmesini sağlayan bir araç olarak kullanıldığı söylenebilir. Bunların yanısıra, senaryoların yöneticiler arası iletişimi iyileştirdiği ve gelecekle ilgili tartışmalar için ortak bir çerçeve çizdiği de unutulmamalıdır.

Sonuç olarak senaryo analizlerinin amacının; yönetsel öğrenmeye destek vermek için gelecekle ilgili bir dizi tahmin geliştirerek geleceğin hipotetik görüntülerinin oluşturulması ve bu görüntülerin stratejiler belirlemek ve sözkonusu stratejileri test etmek için kullanılması olduğu söylenebilir.

Bu amaç doğrultusunda, senaryo analizi

- stratejik planlama ve karar analizini;
- risk ve duyarlılık analizlerini;
- yaratıcılık ve organizasyonel öğrenmeyi tek tek ya da bütün olarak destekler.

Bu yüzden senaryo süreci temel olarak değişmese de fonksiyonları, bir başka deyişle kullanım alanları kişilere ve/veya organizasyonlara bağlı olarak değişim gösterebilir (Bood ve Postma, 1997). Senaryoların temel fonksiyonları şöyle sıralanabilir:

- Stratejilerin değerlendirilmesi ve seçimi: Senaryolar karar vericilerin dikkate aldığı çeşitli etken ve bilgiyi bir çerçeveye sokar ve strateji belirlenmesini kolaylaştırır. Bunun yanısıra, bir karar analizi yaklaşımı ile kullanıldığında esnekliği artırır, planlamayı kolaylaştırır (Bunn ve Salo, 1993). Stratejilerin risk ve dayanıklılık (robustness) analizlerine de yardımcı olur.

- Gelecek-merkezli çeşitli veri türlerinin bütünleşimi: Senaryolar sadece nicel değil nitel verileri de barındırdığı ve değişik tahmin tekniklerinin sonuçlarını kullanabildiği, ayrıca bulanık veri kullanımına da izin verdiği ve bu veri tiplerini bünyesinde birleştirebildiği için strateji oluşturmada önemli bir yere sahiptirler (Bood ve Postma, 1997).
- Geleceğin ve gelecekle ilgili olasılıkların ortaya konması: Senaryolar yöneticilere geçici değil önemli olan durumların neler olduğu konusunda fikir verirler. Eğer değişik senaryolara bağlı hareket planları hazırlanırsa belirsizlikler karşısında bir erken uyarı sistemi görevi de görürler.
- Yöneticilerin çevresel belirsizliklerden haberdar edilmesi: Belirsizlik günümüz dünyasının temel özelliği olduğu için, onu anlamak, kabullenmek ve yapılan çıkarımların bir parçası haline getirmek senaryolar aracılığı ile gerçekleştirilebilir. Senaryolar yöneticilerin belirsizlikle başa çıkmalarının yolu olarak onu yoksaymayı değil aksine ortaya koyarak olası etkilerini incelemelerini zorunlu kılar (Wollenberg ve diğ., 2000).
- Yöneticilerin zihinsel modellerinin ortaya konması: Herbir yöneticinin farklı olaylar karşısında farklı düşünce ve davranış yapısı, dolayısı ile farklı zihinsel modelleri vardır (Bood ve Postma, 1997). Bu modellerin ortaya konması ve birleştirilmesi senaryolar ile mümkün hale getirilir.
- Organizasyonel öğrenmenin desteklenmesi ve hızlandırılması: Senaryolar gerçek dünyanın bir gösterimi olarak düşünüldüğünde yöneticilerin test edip üzerinde oynayabildikleri ve böylece daha çabuk öğrenebildikleri bir geçiş aracı olarak hizmet ederler. Ayrıca şaşırtıcı senaryolar da yöneticileri beklenmeyen planlama durumlarına sokar ki bu da yönetim kademesinin çevresel belirsizlikleri öğrenmesine ve kolay adapte olmasına yardımcı olur (Bunn ve Salo, 1993).

Temelde modern senaryo analizi yöneticilere onları çevreleyen dünya hakkında birbirinden değişik görüş açıları sağlayarak, düşünce sistemlerini etkilemeyi hedefler (Bood ve Postma, 1997).

Kişilerin algılama farklılıkları geleceği görüş şekillerini de bütünüyle etkiler. Geleceğe bakıldığında bir konu ile ilgili durumların gelişebilme olasılıkları üstel

olarak artış gösterir. Oysa bilişsel yetersizlikler nedeniyle bireyler bu gelecek görüntüsünün sadece belirli bir kısmını algırlar. Bu aşamada senaryolar farklı gelecek görüntülerini ortaya koyabildikleri için önemlidirler, çünkü bu sayede kişisel yetersizlikler nedeniyle gözardı edilebilecek çeşitli durumlar ortaya konmuş, ve organizasyonel öğrenme ile stratejik karar verme süreci desteklenmiş olur. Bunun nedeni senaryoların gelecekle ilgili bir çeşit deney-test seti olarak kullanılabilmesi ve yöneticilerin hayal gücünü genişletebilmesidir.

1.4 Senaryo Analizinin Sonuçları

Senaryolar, stratejik gelişimin daha dinamik ve gerçekçi olmasını sağlarken, stratejik öğrenmenin temelinde yatan faktörlerin de etkin kullanımını sağlarlar. Bir organizasyonda senaryo analizinin kullanılmasının sonuçları şöyle özetlenebilir:

- Öğrenmenin engellenmesini ortadan kaldırır: Çeşitli senaryolar belirsizliklerin ortaya konmasını, deneyimlerin paylaşılmasını sağlar ve böylece farklı kişilerin zihinsel modelleri birbiri ile uyumlu hale getirilebilir. Bunun yanısıra geleceği çeşitli yönleriyle ortaya koyduğu ve değişik stratejik seçenekler üzerinde önceden düşünülmesini sağladığı için organizasyonel öğrenmede oluşabilecek gecikmeleri ortadan kaldırmış olur.
- Yaratıcılığı destekler: Senaryo analizi yöneticileri analizin merkezine koyar ve onları çevreleyen dünya hakkında ne düşündüklerine odaklanır. Böylece belirsizlikler ve karmaşıklıklar ortaya çıkar. Oysa SWOT analizi gibi geleneksel tekniklerde amaç olabildiğince basit bir model oluşturmaktır. Bunun yanısıra geleneksel teknikler geçmiş ve bugün ile ilgilenirler. Oysa senaryo analizi karmaşık, belirsizliklerle dolu bir gelecek ile ilgilenirken yaratıcı olmayı da zorunlu kılar. Dahası, diğer teknikler geleceğin nasıl görüneceği ile ilgilenirken senaryo analizi yöneticileri durum değerlendirmesi hareket planı oluşturma bilinen çerçevesini kırıp yaratıcı düşünmeye ve böylece geleceğe daha iyi uyum sağlamaya olanak tanır (Wollenberg ve diğ., 2000).
- Organizasyonel öğrenmeyi geliştirir: Senaryolar yöneticilerin kısıtlı bilişsel yeteneklerinin farkında olmalarını sağlar (Bood ve Postma, 1997). Düşünmenin etkin bir yolu olarak alternatif senaryolar ortaya koymak, geleceğin

düşünülenden daha belirsiz olduğunu gözler önüne serer. Böylece yöneticiler mevcut zihinsel modellerini gözden geçirmek zorunda kalırlar ve gelecekle ilgili düşünürken aynı zamanda birbirlerinden farklı görüş açıları da öğrenmiş olurlar. Senaryolar bu yüzden öğrenmenin sağlanması etkin bir mekanizma olarak düşünülebilirler (Wollenberg ve diğ., 2000).

- Sistem görüşü sağlar: Senaryo analizi gücünü temelinde sistem görüşü olmasından alır. Makro düzeydeki çevresel güçlere senaryo oluşumunda risk kaynakları ve değişim güçleri olarak özel önem verilir. Bunun için de incelenen konuya sistem görüşü ile yaklaşmak zorunludur. Bunun yanı sıra, sistem yaklaşımı senaryoların bünyelerinde barındırdığı birçok olay ve eğilim arasında varolabilecek tutarsızlıkların da ortadan kaldırılmasını sağlar (Becker, 1983).


1.5 Senaryoların Yapıları

Senaryoların yapısı, içinde bulunulan durumun karmaşıklığı ve belirsizliği gözönünde bulundurularak ortaya konulabilir (Schoemaker, 1993). Şekil 1.2'de planlama için kullanılan yöntemler iki boyutlu bir grafik üzerinde gösterilmiştir.

Belirsizlik ile kastedilen, stratejik olarak ilgili bir değişkenin nedensel yapısının bilinmeme derecesidir. Karmaşıklık ise sözkonusu değişkene ait nedensel yapının tek olup olmadığını ortaya koyar. Eğer ilgili değişken diğer değişkenlerden bağımsızsa, karmaşıklık düşük; tersine, kuvvetli ilişkiler varsa karmaşıklık yüksek olarak tanımlanır.

Belirsizlik ve karmaşıklığın düşük olduğu durumlarda; organizasyonların çoğu noktasal tahminleri kullanır. Belirsizlik yüksek olduğunda ise noktasal tahminler önemini yitirip yerine olasılık dağılımları kullanmak daha uygun hale gelir.

Yüksek karmaşıklık sözkonusu olduğunda ise değişkenler arası ilişkileri ortaya koyacak modeller kurmak en sık yapılan şeydir. Yüksek karmaşıklık ama düşük belirsizlik olduğunda deterministik modeller uygun olabilir. Yine de makro düzeyde deterministik modellerin performansının düştüğü de gözönünde bulundurulmalıdır.



Şekil 1.3 Planlama Yaklaşımları (Schoemaker, 1993, s.198)

Hem karmaşıklık hem de belirsizlik yüksek olduğunda ise stokastik modeller kullanılabilir. Ancak akademik olarak ideal olsalar da stokastik modeller gerçek hayatta strateji alanında iyi sonuçlar vermezler. Kullanımları stok-üretim modelleri, kuyruk simülasyonları, finansal modeller ve pazarlama ile sınırlıdır. Böylesi durumlarda senaryo analizi; teori ve pratik arasında dengeyi sağlayarak iyi bir çözüm oluştururlar.

Senaryo sözcüğü birden çok yaklaşımı kapsayacak denli genel bir tanımlamadır (Bunn ve Salo, 1993). Bu yaklaşımlar senaryoların yapısı gözönünde bulundurularak sınıflandırılabilir. Ancak senaryolar, zaman, amaç, kavram gibi birçok boyuta göre sınıflandırılabilirler (Raubitschek, 1988). Önerilen en geniş sınıflandırmalardan biri senaryoları tiplerine göre 3 sınıfa ayırır.

- Çevresel senaryolar: Organizasyonların dışındaki gelişmelerle ilgilenir. Çevresel senaryolar ekonomik, politik, sosyal gibi global, makro düzeydeki değişkenler üzerine odaklanırlar. Ancak bu senaryolar makro düzeyde oldukları için çok genel bir bakış açısı sağladıklarından, sözkonusu senaryoları kullanarak şirkete ait stratejiler geliştirmek zordur.

- Şirkete özel senaryolar: Gelişmeler mikro düzeyde ortaya konur ve şirketin yeni pazar fırsatları ya da teknolojik gelişmeler gibi dış ve iç faktörlere vereceği tepkiler üzerine odaklanılır.
- Karma senaryolar: Bu tip senaryolar diğer iki tip senaryonun karması olarak düşünülebilir. Çevredeki gelişmeler ile şirketin tepkileri arasındaki ilişkiler üzerine odaklanmıştır. Strateji geliştirmede oldukça önemlidirler çünkü şirketin çevresindeki kritik elemanları ortaya koyarken bu gelişmelere şirketin vereceği tepkiler ile de ilgilenilmesine olanak tanınmış olur.

Bunn ve Salo göre ise (1993) yapılabilecek ilk sınıflandırma senaryo analizinin başlangıç noktası temel alınarak yapılabilecek olan sınıflamadır. Buna göre senaryolar araştırmacı ve sezinleyici senaryolar olmak üzere ikiye ayrılabilir.

- Araştırmacı senaryolar: Bu senaryolar için başlangıç noktası mevcut zamandır. Gelecekle ilgili çıkarımlar mevcut zaman gözönünde bulundurularak yapılır ve zaman akışının doğallığı ile gelecekle ilgili düşüncelerin alışık olunan tarzı bozulmaz. Böylece oluşturulan senaryolar gerçekçi olsa da şaşırtıcı değildir ve zaman zaman bazı olasılıkların atlanma tehlikesi bulunur. Bu tarz senaryoların kavramsal bir benzetimi karar ağaçlarıdır. Bu tip senaryolarda esas amaç, ele alınan sistemin temel öğelerinin gelecekte alabilecekleri çeşitli değerleri dikkate alarak, olası bir gelecek için mantıksal olarak gerekli gözükten olayları ortaya koymak ve böylece alternatif gelecek senaryoları irdelemektir (Pamuk ve diğ., 1997).
- Sezinleyici senaryolar: Bu senaryoların oluşturulması ise belirli bir gelecek durumu gözönünde bulundurarak bu duruma yolaçan olası nedenleri incelemek üzerine kuruludur (Bunn ve Salo, 1993). Başlangıç noktası gelecek olduğu için, bu tarz senaryolar hedefler üzerinde daha yoğunlaşır ve geri çıkarım yaparak sonuçlardan çok açıklamalar üzerinde durur. Bu yüzden de bu senaryolar yeni seçeneklerin keşfedilmesine olanak tanır ve diğer tip senaryoya göre daha şaşırtıcıdır.

İkinci bir sınıflama da tanımlayıcı (descriptive) ve şekillendirici (normative) senaryolar olmak üzere senaryoları yine ikiye ayırır. Tanımlayıcı senaryolar gelecekle ilgili olayları ve eğilimleri, onların istenip istenilmediğine dair yorum

yapmaksızın tanımlarlar. Şekillendirici senaryolar ise oluşturulan senaryoyu kullanacak kişinin istek ve motivasyonunu da dikkate alırlar.

Bir diğer sınıflama ise eğilim senaryoları ile çevresel senaryolar olmak üzere yine iki ayrı tip senaryo ortaya koyar. Eğilim senaryolarında varolan eğilimler geleceğe yansıtılırken eğer varsa sadece birkaç tane beklenmeyen eleman eklenir. Çevresel senaryolarda ise değişkenlere uç değerler atanır ve çok daha şaşırtıcı gelişimler ortaya konur.

Godet'ye göre ise (1994) senaryolar üç tipte olabilirler.

- Olası senaryolar: Gelecekle ilgili hayal edilebilen tüm durumlardır.
- Gerçekçi senaryolar: Olası senaryolar içerisinde kısıtlarla daraltılmış gelecek görüntüleridir.
- İstenen senaryolar: Olası senaryolar içinde olsa da gerçekçi olmak zorunda olmayan senaryolardır.

Bu tez kapsamında ele alınan ve senaryo analizi ile, içerdiği belirsizliklere karşı hazırlıklı olunmaya çalışılan konu olarak enflasyon belirlenmiştir. Bu yüzden yapılan çalışmalar sonucu ortaya çıkacak olan senaryolar çevresel senaryolar olarak tanımlanabilir. Çevresel senaryoların makro düzeyde kalıp, şirketlere ait senaryolar geliştirmenin zorluğunu bünyelerinde barındırmalarına rağmen, tezde incelenilen konunun enflasyon gibi bütün bir ülkeyi ilgilendiren makro bir konu olması nedeniyle sözkonusu problemin ortadan kalkacağı düşünülmektedir. Zira, zaten çalışmanın hedefi şirketlere mikro planlama sorunlarında yardımcı olmak değil ülkenin ekonomisine makro düzeyde ışık tutmak olarak belirlenmiştir.

Bunn ve Salo'ya ait (1993) ikinci sınıflama gözönünde bulundurulduğunda ise yapılan çalışma araştırmacı senaryo çalışması olarak adlandırılabilir. Zira çalışma kapsamında geçmiş verilerden yola çıkılarak senaryolar için başlangıç zamanı içinde bulunulan zaman olarak belirlenmiş ve oluşturulan senaryolar ışığında gelecekle ilgili belirsizlikler ortadan kaldırılmaya çalışılmıştır. Bu tarz senaryolara ait olan gelecekle ilgili bazı önemli olasılıkların atlanması tehlikesi ise çalışma kapsamında

izlenilen süreçte kullanılan bilişsel haritalar; EFAR ve yapay sinir ağları teknikleri ile büyük ölçüde ortadan kaldırılmıştır.

Diğer sınıflamalar ışığında ise, tez kapsamında incelenilen senaryoların gelecekle ilgili olayları senaryoları kullanacak kişi ve/veya kişilerin isteklerinden bağımsız bir şekilde ortaya konmaları nedeniyle “tanımlayıcı”; ve yapılan incelemeler sırasında varolan eğilimler dikkate alındığından “eğilim” tipi olduğu söylenebilir. Godet’nin (1994) yaklaşımı dikkate alınır ise; yapılan çalışmadaki senaryolar; olası tüm senaryolar içinden kısıtlarla daraltılmış gerçekçi görüntüleri barındırdığından “gerçekçi” senaryolar olarak tanımlanabilirler.

Senaryolar için önerilen sayı, literatürde farklılık göstermekle beraber çoğu yazar üç ile dokuz arası senaryonun kullanılmasını önermektedir (Wollenberg ve diğ., 2000). Oluşturulan senaryoların sayısı aslında analizin kapsamına bağlı olarak değişim gösterir. Grup öğrenmesini hedefleyen basit örneklerde bir senaryo bile yeterli olabilecekken, çok sayıda belirsizlik karşısında verilen bir kararın doğruluğu test edilmek isteniyorsa daha çok senaryoya gereksinim duyulacağı açıktır. Yine de bilişsel çalışmalarla kanıtlandığı üzere, bireylerin aynı anda ancak 9 farklı senaryoyu karşılaştırabilecekleri akılda tutulmalıdır.

Bunun yanı sıra özellikle son yıllarda gelecek görüntüsü geçmişe göre daha belirsiz hale geldiğinden, planlamacılar ve tahminciler gelecekle ilgili sadece bir değil birbirinden farklı alternatif gelecek görüntüleri öngördüklerinden senaryo analiz çalışmasında sadece bir senaryonun yeterli olmayacağı açıktır (Becker, 1983). Alternatif senaryoların varlığı ise karar vermeci ve planlamacılara bu alternatif senaryolara olasılık atanması seçeneğini de beraberinde getirmiştir. Böylece zor olsa da her bir senaryoya gelecekte oluşma olasılığı tahmin edilerek bir değer de atanabilir.

1.6 Senaryo Analizinin Geliştirilmesi

Senaryo analiz sürecinin en önemli eksikliği süreç sonunda oluşturulan senaryoların birbirinden ayrık olmalarıdır. Oysa gelecekle ilgili olası görüntüler üzerinde fikir yürütmek için sözkonusu gelecek görüntülerinin birbirleriyle olan ilişkilerinin de gözönünde olması, durumlar arası geçişin daha ayrıntılı bir şekilde incelenebilmesi

ve senaryolar ışığında stratejiler geliştirilmesi için oldukça önem taşımaktadır. Bunun dışında kısıtlı sayıda senaryo da; yine gelecekle ilgili çok sayıda olası görüntünün gözardı edilmesine neden olabilir.

Bu nedenle, bu tez kapsamında senaryo analizine dinamik bir bakış açısı getiren ve yukarıda bahsedilen dezavantajları ortadan kaldıran bir yöntem olduğu düşünülen EFAR (Extended Field Anomaly Relaxation) tekniği üzerinde durulmuştur. Powell (1997) tarafından ortaya konulan sözkonusu yöntem, gelecekle ilgili çok sayıda olası durumu birbiriyle ilişkili bir şekilde ele alan bir senaryo analizi yapısını önermektedir ve 2.Bölümde ayrıntılı bir şekilde açıklanacaktır.

Senaryoların oluşturulması aşamasında incelenilen konu ile ilgili gerekli bilginin alınması için uzmanların çevredeki değişkenler ile aralarındaki ilişkiyi algılayışlarının basitleştirilmiş gösterimleri olan zihinsel modellerden diğer bir deyişle bilişsel haritalardan yararlanılabilir (Bunn ve Salo, 1992). Bu; ek bir çaba ve zaman gerektirse de yararı tartışılmaz. Zira dikkati sadece gelecek üzerinde yoğunlaştırıp olayları ve eğilimleri geçmiş ve mevcut zamanla ilişkilendirmemek bazı önemli ilişkilerin ve olayların gözardı edilmesine yolaçabilir. Bu yüzden; bilişsel haritalar yönteminden, uzmanlardan senaryo analizi yapılacak konu ile ilgili verileri derlemek üzere yararlanmak, sürecin başında ek bir zaman ve çabaya neden olsa da sonrasında daha sağlıklı senaryoların ortaya konmasına yardımcı olacaktır. Bu amaçla, 3.Bölüm'de bilişsel harita yönteminden ayrıntılı bir şekilde bahsedilecektir.

Geleneksel senaryo analiz yaklaşımına daha dinamik bir boyut kazandırmayı hedefini gerçekleştirmek için yoğun olarak yararlanılan ve önerilen süreç boyunca yapılması gereken tahmin ve kümeleme çalışmaları için kullanılan yapay sinir ağları hakkında ise 4.Bölümde bilgi verilmiştir.

2 EFAR YAKLAŞIMI


İş hayatında birçok stratejik karar belirsiz, karmaşık ve şeffaflıktan uzak bir ortamda verilmeye çalışılırken senaryo analizinin bu belirsizliğe büyük ölçüde hazırlıklı olunmasını sağladığı ve stratejik planlama sürecine verdiği destek üzerinde ilk bölümde durulmuştur. Bu bölümde anlatılacak olan, Powell ve Coyle (1997) tarafından ortaya konulan EFAR – Durum Bozukluklarının Giderilmesi İçin İyileştirilmiş Bir Yaklaşım (Extended Field Anomaly Relaxation) yöntemi ise senaryo analizine farklı bir yaklaşım önermekte ve ona daha dinamik bir boyut kazandırmaktadır.

Senaryo analizi, belirsizlik ve karmaşık bir çevre ile başedilebilmesine ve stratejik planlama ile karar verme konularına destek olsa da, önemli bir zayıflığı sınırlı sayıda ve birbirinden izole bireysel senaryolarla çalışılmasıdır (Powell ve Coyle, 1997). Bunun yerine önerilen EFAR yaklaşımı bu zayıflığı gidermeyi amaçlamaktadır. Yöntemin, gelecekteki en olası durumu ortaya koyma gibi bir hedefi yoktur (Coyle ve diğ., 1994). Diğer bir deyişle gelecekteki durumların gerçekleşme olasılıkları üzerinde durulmaz. Bunun yerine eldeki bilginin biraraya getirilmesi yardımıyla oluşturulmuş ve içsel tutarlılıkları sağlanmış küçük olası durumların gruplarıyla ilgilenilir.

Sözkonusu yöntem Rhyne (1974, 1981) tarafından ortaya konulan FAR yönteminin geliştirilmiş halidir. FAR, ilgilenilen sistemin belirli düzeylere sahip bir grup gösterge ile ortaya konulmasını sağlar. Bu şekilde betimlenen sistem, daha sonra gelecekle ilgili bir dizi durumu yaratır. Bu durumlar dizisi, bir zaman ekseninde bir durumdan diğerine geçiş gelişimi görülebilecek şekilde ortaya konulurlar. Ancak zaman ekseninde ortaya konulan bu durumlar, tek yönlü ilişkilendirildiklerinden; ve gerçek hayatta bir durumdan diğerine geçiş genellikle çift yönlü olduğundan sözkonusu FAR yöntemi geliştirilmiştir. Powell ve Coyle (1997), tarafından EFAR olarak adlandırılan, gelecekle ilgili durumların, birbirleriyle çift yönlü olarak ilişkilendirmiş oldukları bir ağ şeklinde ortaya konulmalarını sağlayan

iyileştirilmiş yeni bir yapı oluşturulmuştur. Bu şekilde, yaratılan gelecekle ilgili durumlardan oluşan grup, içerik olarak zengin bir gelecek görüntüsü çizmektedir.

Akış diyagramı Şekil 2.1'de verilmiş olan EFAR yaklaşımı prosedürel bir süreç ortaya koyarken büyük ölçüde öznel yargıları temel alır (Powell, 1997).



Şekil 2.1 EFAR Yaklaşımının Adımları

Yöntemin çıktısı; düğümlerinin herbiri gelecekle ilgili bir durumu tanımlayan bir ağdır. Bu ağ, tercih edilen durumlara geçişin sağlanması ya da tam tersi, daha az istenen durumlara geçişin engellenmesi için neler yapılabileceği ile ilgili stratejik hareket planının çıkarılmasını hızlandırır ve kolaylaştırır. Bu yüzden geleneksel senaryo yaklaşımını temel alsa da, EFAR yaklaşımı gelecekle ilgili durumların birbirleriyle olan bağlantısının ortaya konulabilmesine ve gelecekle ilgili çok sayıda durumun, diğer bir deyişle senaryonun, dikkate alınabilmesine olanak vermesi ile daha avantajlı bir konuma oturtulabilmektedir. EFAR yaklaşımı, izlediği süreç nedeniyle çalışılan konunun ayrıntılı analizine olanak tanırken ortaya koyduğu çıktı aracılığıyla da aynı zamanda bir stratejik planlama aracı olarak da hizmet eder.

Yöntemin adımları daha sonraki bölümlerde ayrıntılı bir şekilde anlatılmıştır.

2.1 Değişkenlerin Listelenmesi

İçinde bulunulan çevrenin temel özellikleri ya da yöntemde adlandırıldıkları üzere değişkenler, gelecekle ilgili önemli olduğu düşünülen kavramlardır. Değişkenler, çalışılan konu ile ilgili iç (hedeflerin kapsamı ya da kaynak durumu) ve dış (pazar durumu ya da çevresel algı) özelliklerin bir karması şeklindedir (Powell ve Coyle, 1997). Bazı değişkenler organizasyon tarafından dolaysız bir şekilde kontrol edilebilirken (hedeflerin kapsamı ya da organizasyonel yerleşim) bazıları sadece dolaylı bir şekilde (hisse senedi fiyatı ya da çevresel algı) kontrol edilebilir. Ancak değişkenlerin sayılarının fazla olmaması sürecin daha etkin işlemesi için gereklidir ve bu sayının yarım düzineyi geçmemesi önerilmektedir.

Üzerinde çalışılan konu ile ilgili değişkenlerin belirlenmesinde Gappert (1973), tarafından önerilen yöntemin kullanılması bu aşamanın etkin bir şekilde tamamlanmasına yardımcı olabilir. Gappert'a göre, incelenilen sistem ile ilgili çok sayıda (100 civarı) özellik belirlenip daha sonra bu çok sayıdaki terim belirli gruplar altında toplanabilir.

2.2 Değişken Düzeylerinin Belirlenmesi

Her bir değişken için bir düzey dağılımı saptanmalıdır (Powell ve Coyle, 1997). Öyle ki sözkonusu değişkenlere bu düzeyleri adlandıracak kodlar verilmesi ve ayrı ayrı kod-değişken ikililerinin birleştirilmesi, birbirinden farklı durumların ortaya çıkmasına yol açmalıdır. Gappert (1973), sözkonusu düzeyleri, değişkenler için alternatif durumlar olarak tanımlamıştır.

Gerçek hayatta değişken-kod ikililerin sayısının üzerinde çalışmaya olanak vermeyecek kadar çok olması beklenir (Powell ve Coyle, 1997). Bu yüzden yöntemde sözkonusu değişkenler ve ilgili kodlarının kısıtlı tutulması gereklidir. Ancak bu aşamada, yani değişken ve düzey sayıları kısıtlı tutulmaya çalışılırken, dikkate alınmayan bazı değişkenlerin gelecekte yaratabilecekleri olası önemli etkilerinin göz ardı edilmesi, yöntemin, izlenen süreç boyunca karşılaşılan ilk dezavantajıdır.

Örnek olarak bir merkez ile bu merkeze bağlı bir ofise sahip ve gelecekteki başarının şirketin hisse dağılım durumu ile organizasyonel durumuna bağlı olduğuna karar

vermiş bir organizasyonun değişken-düzey tablosu Tablo 2.1’de verilmiştir (Powell, 1997) . Tablodan da görülebileceği gibi yatay ekseninde değişkenler, dikey ekseninde ise düzey kodları yer almaktadır. Kodların da tıpkı değişkenlerde olduğu gibi altı adet civarı olması inceleme kolaylığı sağlaması açısından önerilmektedir.

Tablo 2.1 Örnek Değişken-Düzey Tablosu (Powell, 1997, s.859)

5	Tercih edilen ya da gerekli ortak			Tercih edilen tedarikçi			
4	İşbirliğine istekli ortaklar	Hücre pozisyonu ile güvenlik sağlama	Hepsinin satışı	Algıda iyileşme	Zamanında karşılanılan dağıtım	Tek merkez	Çoğu için yeterli
3	Mevcut durum	Artan bir şekilde büyüme	Çoğunluğun satışı	Mevcut durum	Mevcut durum	Tek merkez+bir ön ofis	Gelişme için yeterli
2	Agresif rakipler	Var olma	Azınlık hisselerin satışı	Algıda kötüleşme	Yetersiz pazarlama	Geliştirilmiş iki ofis	Küçük değişim için yeterli
1	Şirkete odaklanmış rakipler	Yok olma	Mevcut durum	Son tercih edilen tedarikçi	Pazara uygun olmama	Mevcut durum (iki ofis)	Mevcut durumu koruma için yeterli
	R	B	H	Ç	D	O	K
	Rekabet Durumu	Büyüme Durumu	Hisse Dağılımı	Çevre Algısı	Dağıtım Kapasitesi	Organizasyonel Durum	Kaynak Durumu

Değişken olarak ortaya konulan özelliklerin yeterince iyi olup olmadığının en temel göstergesi Tablo 2.2’deki matriste boş göz olmaması durumudur. Böylece çalışma kapsamında hem iç hem dış özelliklerin yanısıra, doğrudan kontrol edilebilen ve edilemeyen değişkenlere yer verilip verilmemiş olduğu da bu matris yardımı ile anlaşılabilir.

Tablo 2.2 Kontrol Matrisi (Powell, 1997, s.859)

	Doğrudan Kontrol Edilebilir	Dolaylı Kontrol Edilebilir
İçsel	H, O	R,B,K
Dışsal	D	Ç

2.3 Anlamsız Bileşimlerin Elenmesi

EFAR sürecindeki üçüncü adım, kodları atanmış değişkenlerin olanaklı ve olanaksız bileşimlerin ortaya konmasıdır. Bunun için de her bir değişken-kod çiftinin diğer çiftlerle karşılaştırılması gereklidir. Zira, hücre pozisyonu ile güvenlik sağlama

durumu ile son tercih edilen tedarikçi olma gibi birarada bulunması olanaksız bileşimler her zaman mümkündür. Bu yüzden, Tablo 2.3’de verilen uygunluk matrisi ile olanaklı bileşimlerin ortaya konması şarttır.

Tablo 2.3 Uygunluk Matrisi (Powell, 1997, s.861)

R	B	H	Ç	D	O	K
1	1 2 - -	1 2 3 4	- - 4 5	- - 3 4	1 2 3 4 5	1 2 3 -
2	1 2 3 4	1 2 3 4	- - 3 4 5	- - 3 4	1 2 3 4 5	1 2 3 -
3	1 2 3 4	1 2 3 4	1 2 3 4 5	1 2 3 -	1 2 3 4 5	- 2 3 4
4	- 2 3 4	- - 3 4	- - 3 4 5	- - 3 4	1 2 3 4 5	- - 3 4
5	- - - 4	- - 3 4	- - - 4 5	- - - 4	1 2 3 4 5	- - 3 4
	1	- - 3 4	1 2 3 4 5	1 2 3 4	1 2 3 4	1 2 - -
	2	1 2 3 -	- - 3 - -	- - 3 4	1 2 - -	1 2 3 -
	3	1 2 3 -	- - 3 4 -	- - 3 4	- 2 3 4	- - 3 4
	4	1 2 3 -	- - - 4 5	- - - 4	- - 3 4	- - 3 4
		1	1 2 3 4 5	1 2 3	1 2 3 4	1 2 - -
		2	- - 3 4 5	- - 3 4	- 2 3 4	- 2 3 4
		3	- - 3 4 5	- 2 3 4	- 2 3 4	- - 3 4
		4	- - 3 4 5	- 2 3 4	1 2 3 4	- - 3 4
			1	1 2 - -	1 2 3 4	1 2 - -
			2	1 2 - -	1 2 3 4	1 2 - -
			3	- - 3 4	1 2 3 4	- 2 3 -
			4	- - 3 4	- 2 3 4	- - 3 4
			5	- - - 4	- 2 3 4	- - 3 4
				1	1 2 3 -	1 - - -
				2	1 2 3 -	1 2 - -
				3	1 2 3 4	- 2 3 -
				4	- 2 3 4	- - 3 4
					1	1 2 - -
					2	- 2 - -
					3	- - 3 4
					4	- - - 4

Sözkonusu tabloda olanaksız durumlar “-” ile gösterilmiştir. Böylece, örneğin, tablonun incelemesi ile eğer büyüme durumu ile ilgili kod 1 ise, hisse dağılımının sadece 3 ve 4 kodlarını alabileceği; buna bağlı olarak da çevre algısının sadece 3, 4 ve 5 kodlarını alabileceği görülmüş olur. Böylece uygunluk matrisi, ikili

bileşimlerden yola çıkarak üçlü, dörtlü ve beşli bileşimlerin incelenmesine de olanak sağlamış olur. Ancak yine önemli bir eksiklik olarak, uygunluk matrisinin hazırlanması aşaması da, içinde bulunulan işle ilgili yeterli bilgi ve birikime sahip olduğuna inanılan kişilerle yapılan görüşmelere ve dolayısı ile tamamen öznel bilgiye dayanır.

2.4 Olurlu Bileşimlerin Kümelenmesi

Tablo 2.3’de verilen matrisin incelenmesi ile olanaklı bileşimler ortaya çıkabilir. Örnek çalışmada toplam 66 adet olanaklı durum saptanmıştır. Tablo 2.4’de sözkonusu olanaklı (uygun) durumların bir listesi verilmiştir. Bu uygunluk çalışmasının yapılmaması, çalışmada gelecekle ilgili 25000 adet durumun ortaya çıkmasına neden olur ki, çalışmanın bu koşullarda gerçekleştirilemeyeceği açıktır.

Uygun durumların ortaya konmasından sonra, benzer olan durumların birleştirilmesi gereklidir, çünkü her ne kadar 66 durum, 25000 ile kıyaslandığında çok az olsa da yine de incelenmesi ve akılda tutulması zordur. Bu yüzden düzeyleri birbirine yakın olan durumların birleştirilmesi gereklidir. Bu aşamada da yöntemin en önemli dezavantajlarından biri olarak, yine öznel bilgiden yararlanılır ve Tablo 2.5’de kodlarıyla birlikte verilen toplam 29 bileşim çalışmanın merkezini oluşturur. Ancak bu birleştirme sırasında değişkenlerin kodlarının birbirlerine yakın olması (aralarındaki farkın en çok 1 olması) gibi anlamlı olmayan bir değerlendirme yapılmaktadır. Zira, değişkenlerin kodları, sadece ilgilenilen değişkene ait düzeyleri belirtmek içindir. Oysa, bu aşamada sanki her bir kodun aynı ölçek üzerinde konumlandırılabilir bir belirli bir sayısal değeri varmış ve kodlar arası mesafe her bir değişken için aynıymış gibi hareket edilmektedir. Bu da yöntemin üzerinde durulması gereken diğer bir eksikliği olarak düşünülmelidir.

Sonuçta ortaya çıkan her bir durum ise, bileşim sonucu oluşmuş da olsa, artık bu aşamadan sonra olası bir geleceği belirteceğinden önemlidir. Sözkonusu 29 durumdan herbiri gelecekle ilgili bir görüntüyü betimler. Örneğin 46+47 olarak birleştirilen durumun gelecekle ilgili betimlemesi “iyi bir ürün performansı ve rakiplerle olumlu ilişkiler ışığında hisselerin çoğunluğunun satışı ile daha fazla gelişme sağlamak için kaynak yaratılması” olarak ortaya konulabilir. Bir diğer örnek de 35+36 olarak birleştirilen gelecek durumu ile verilebilir. Bu durum da “iyi bir

ürün performansına rağmen şirketin iş yapamaması ve iş hayatında çekilmesi” olarak betimlenebilir.

Tablo 2.4 Uygun Durumların Listesi (Powell, 1997, s.871)

	R	B	H	Ç	D	O	K		R	B	H	Ç	D	O	K
1	1	1	3	4	3	3	3	34	3	1	3	4	3	3	3
2	1	1	3	4	4	3	3	35	3	1	4	3	3	3	3
3	1	1	3	5	4	3	3	36	3	1	4	4	3	3	3
4	1	1	4	4	3	3	3	37	3	2	1	3	3	2	2
5	1	1	4	4	4	3	3	38	3	2	2	3	3	2	2
6	1	1	4	5	4	3	3	39	3	2	2	3	3	3	3
7	2	1	3	4	3	3	3	40	3	2	3	3	3	3	3
8	2	1	3	4	4	3	3	41	3	3	2	3	3	3	3
9	2	1	3	5	4	3	3	42	3	3	2	4	3	3	3
10	2	1	4	3	3	3	3	43	3	3	3	3	3	3	3
11	2	1	4	3	4	3	3	44	3	3	3	4	3	3	3
12	2	1	4	4	3	3	3	45	4	2	3	3	3	3	3
13	2	1	4	4	4	3	3	46	4	2	3	3	4	3	3
14	2	2	4	5	4	3	3	47	4	2	3	3	4	3	4
15	2	2	1	3	3	2	2	48	4	3	3	3	3	3	3
16	2	2	2	3	3	2	2	49	4	3	3	3	4	3	3
17	2	2	2	3	3	3	3	50	4	3	3	3	4	3	4
18	2	2	2	3	4	3	3	51	4	3	3	4	3	3	3
19	2	2	3	3	3	3	3	52	4	3	3	4	4	3	3
20	2	2	3	3	4	3	3	53	4	3	3	4	4	3	4
21	2	2	2	3	3	3	3	54	4	3	3	4	4	4	4
22	2	3	2	3	4	3	3	55	4	4	3	4	4	3	3
23	2	3	2	4	3	3	3	56	4	4	3	4	4	3	4
24	2	3	2	4	4	3	3	57	4	3	4	4	3	4	4
25	2	3	3	3	3	3	3	58	4	3	4	5	4	3	3
26	2	3	3	3	4	3	3	59	4	3	4	5	4	3	4
27	2	3	3	4	3	3	3	60	4	3	4	5	4	4	4
28	2	3	3	4	4	3	3	61	5	4	3	4	4	3	3
29	2	4	1	4	4	3	3	62	5	4	3	4	4	3	4
30	2	4	1	5	4	3	3	63	5	4	3	4	4	4	4
31	2	4	3	4	4	3	3	64	5	4	3	5	4	3	3
32	3	4	3	5	4	3	3	65	5	4	3	5	4	3	4
33	3	1	3	3	3	3	3	66	5	4	3	5	4	4	4

2.5 Geçiş Matrisinin Oluşturulması

EFAR yaklaşımının en önemli özelliği gelecekle ilgili durumları ortaya koyarken aynı zamanda onların arasındaki geçişleri de bir diğer deyişle hareket olurluluğunu da beraberinde getirmesidir. Bu, Tablo 2.5’de verilen durumların ikili karşılaştırmaları ile yapılabilir. Burada her durum çiftinin incelenmesi, ve birbirleri arasında geçişin olanaklı olup olmadığının tespiti gereklidir.

Tablo 2.5 Gruplanmış Uygun Bileşimler (Powell,1997. s.862)

	R	B	H	Ç	D	O	K
15	2	2	1	3	3	2	2
37	3	2	1	3	3	2	2
29+30	2	4	1	3.5	4	3	3
16+34	2.5	2	2	3	3	2	2
17	2	2	2	3	3	3	3
18	2	2	2	3	4	3	3
39	3	2	2	3	3	3	3
21+29	2	3	2	3	3	3	3
22+23+24	2	3	2	3.5	3.5	3	3
41+42	3	3	2	3.5	3	3	3
1+2+3+7+8+9	1.5	1	3	4.5	3.5	3	3
33+34	3	1	3	3.5	3	3	3
19	2	2	3	3	3	3	3
20	2	2	3	3	4	3	3
40+45	3	2	3	3	3	3	3
46+47	4	2	3	3	4	3	3.5
25+26+27+28	2	3	3	3.5	3.5	3	3
43+44	3	3	3	3.5	3	3	3
48	4	3	3	3	3	3	3
49+51+52	4	3	3	3.5	3.5	3	3
50+53	4	3	3	3	4	3	4
54	4	3	3	4	4	4	4
31+32	2	4	3	4.5	4	3	3
55+56	4	4	3	4	4	3	3
61+64	5	4	3	4.5	4	3	3
62+63+65+66	5	4	3	4	4	3	4
4+5+6+10+11+12+13+14	1	1	4	4	3	3	3
35+36	3	1	4	3.5	3	3	3
58+59+57+60	4	3	4	4.5	3.5	3.5	3.5

Oldukça yorucu olan bu aşama, bir destek yöntem ile kolaylaştırılabilir. Öyle ki, kodları Tablo 2.5'de verilen durumların eğer aralarında belirli bir değerden daha az uzaklık mesafesi varsa geçişin olanaklı olduğu yani geçiş matrisindeki ilgili göz değerinin 1 olacağı, tersi şekilde; belirli bir değerden daha çok mesafe varsa geçişin olanaksız olduğu yani ilgili geçiş matrisi gözünün 0 olacağı düşünülebilir. Geçiş matrisinin oluşturulması için gerekli mesafeleri gösteren matris Tablo 2.6'da verilmiştir. Ancak burada da yine kodlar arası uzaklığın eşit olduğu varsayımı kullanılmıştır.

Bu aşamada sözkonusu alt ve üst değerlerin belirlenmesi ve bu değerler arasında kalan mesafeye sahip ikililerin ne olacağı problemi vardır. Alt ve üst limit değerlerinin belirlenmesi tamamen öznel bilgiyi temel alır. İki değer arasında kalan ikililer ile ilgili problemin de sadece bu durumlar için ikili karşılaştırma yapılması ile üstesinden gelinmesi mümkündür. Örnek çalışmada alt değer 4.5 üst değer ise 5.5 olarak belirlenmiş ve bu iki değer arasında kalan ikililer tekrar incelenip gözden

geçirilmişlerdir. Ortaya çıkan sonuç Tablo 2.7’de verilen geçiş matrisiyle gösterilebilir. Geçiş matrisi incelendiğinde bazı geçişlerin sadece tek yönlü olarak olanaklı olduğu görülebilir. Bunun nedeni bu gözlerin alt ve üst değerler arasında kalan ve öznel değerlendirme ile incelenen gözler olmalarıdır.

Tablo 2.6 Geçiş Matrisi İçin Uzaklıklar (Powell, 1997, s.872)

	15	37	29+	16+	17	18	39	21+	22+	41+	1+	33+	19	20	40+	46+	25+	43+	48	49+	50+	54	31	55	61	62	4+	35+	58+
15		1	5.5	2	3	4	4	4	5	5.5	8	4	5	5	5	8	6	6.5	7	8	9	11	9	10	12	1	8	8.5	12
37			6.5	3	4	5	3	5	6	4.5	8	5.5	5	6	4	7	7	5.5	6	7	8	10	10	9	11	11	9	7.5	11
29+				7.5	5	6	6	3.5	2.5	4	7	7	6	5	6.5	7.5	4	5	7	6	7	8	3	5	6	7	9	8	9.5
16+					3	4	2	4	5	3.5	6	5.5	4	5	3	6	6	4.5	5	6	7	9	9	10	10	10	8	5.5	10
17						1	1	1	2	2.5	5	3.5	1	2	2	5	2	3.5	4	5	6	8	6	7	9	9	5	4.5	9
18							2	2	2	3.5	4	4.5	2	2	3	4	3	4.5	5	5	5	7	5	6	8	8	6	5.5	9
39								2	3	1.5	5	3.5	2	3	2	4	3	2.5	3	4	5	7	7	6	8	8	6	3.5	8
21+									1.5	5	5	2	3	2	3	6	1.5	2.5	3	4	5	7	5	6	8	8	6	5.5	8
22+										1.5	4	4.5	3	3	3	6	1	2.5	4	3	5	4	4	5	7	6	6	5	7
41+											6	3	4	5	2.5	5.5	2.5	1	3	3	5	6	5	5	6	7	7	4	4.5
1+												2.5	3	3	4	6	3	4.5	6	5	7	5	4	6	7	8	3	3.5	7
33+													3	4	1.5	4.5	4	2.5	4	4	6	6	6	6	7	8	4	3	7.5
19														1	1	4	2	2.5	3	4	5	7	5	6	8	8	4	3.5	8
20															2	4	2	3.5	4	4	4	6	4	5	7	7	5	4.5	8
40+																3	3	1.5	2	3	4	6	6	5	7	7	5	2.5	7
46+																	5	4.5	3	3	1	3	7	4	6	4	8	5.5	5
25+																		1.5	3	2	4	5	3	4	6	6	5	4.5	6
43+																			2	2	4	5	4	4	5	6	6	3	5.5
48																				1	2	4	6	3	5	5	7	4.5	5
49+																					2	3	5	2	4	5	7	4.5	4
50+																						2	6	3	5	2	9	6.5	4
54																							6	3	5	3	9	7.5	2
31+																								3	3	5	7	7	6.5
55+																									2	2	8	6.5	5
61+																										2	10	8	5.5
62+																											10	8.5	5
4+																												2.5	6
35+																													6.5
58+																													0

Tablo 2.7 Geçiş Matrisi (Powell, 1997, s.863)

	15	37	29+	16+	17	18	39	21+	22+	41+	1+	33+	19	20	40+	46+	25+	43+	48	49+	50+	54	31	55	61	62	4+	35+	58+
15	1			1	1	1	1	1					1																
37	1	1		1	1		1					1			1														
29+			1					1	1	1							1						1						
16+	1	1		1	1	1	1		1				1	1	1			1											
17				1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1								1	
18				1	1	1	1	1	1	1	1	1	1	1	1	1	1					1							
39				1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1							1	
21+			1		1	1	1	1	1	1	1	1	1	1	1		1	1	1	1		1							
22+			1		1	1	1	1	1	1	1	1	1	1	1		1	1	1	1	1	1	1	1				1	
41+			1		1	1	1	1	1	1	1	1	1	1	1		1	1	1	1	1	1	1	1				1	
1+					1	1	1	1	1	1	1	1	1	1	1		1					1					1	1	
33+					1	1	1	1	1	1	1	1	1	1	1		1	1	1	1							1	1	
19					1	1	1	1	1	1	1	1	1	1	1		1	1	1	1	1	1	1	1			1	1	
20					1	1	1	1	1	1	1	1	1	1	1		1	1	1	1	1	1	1	1			1	1	
40+					1	1	1	1	1	1	1	1	1	1	1		1	1	1	1	1	1	1	1			1	1	
46+					1	1	1					1	1	1	1		1	1	1	1	1		1	1	1				
25+					1	1	1	1	1	1	1	1	1	1	1		1	1	1	1	1	1	1	1	1		1	1	
43+					1		1	1	1	1		1	1	1	1	1	1	1	1	1	1	1	1	1	1			1	
48					1		1	1	1	1		1	1	1	1	1	1	1	1	1	1	1	1	1	1		1	1	
49+						1	1	1	1	1		1	1	1	1	1	1	1	1	1	1	1	1	1	1		1	1	
50+						1		1	1			1	1	1	1	1	1	1	1	1	1	1	1	1	1		1	1	
54								1	1				1	1	1	1	1	1	1	1	1	1	1	1	1		1	1	
31+						1		1	1		1		1	1	1		1	1	1	1			1	1	1				
55+								1	1				1	1	1	1	1	1	1	1	1	1	1	1	1		1	1	
61+															1	1	1	1	1	1		1	1	1	1		1		
62+															1			1	1	1	1		1	1	1				
4+																												1	
35+																												1	
58+																													

Bazı ikililer incelendiğinde bir durumdan diğerine geçiş olanaklı görünürken, tersi, olanaksız olarak düşünülebilir. 33 ve 37 kodlarıyla belirtilen durumlar için böylesi bir durum vardır. Aralarındaki fark 5.5 olduğundan incelenmesi gerektiğine karar verilmiştir. İncelendiğinde ise 37'den 33'ye geçişin mümkün olduğu ancak 33'den 37'ye geçişin mümkün olmadığına karar verilmiştir. çünkü mevcut durumdan

hisselerin büyük çoğunluğun satılması olanaklı iken satılanları geri almak çok da mümkün değildir. Sonuçta bu iki durum arası geçiş tek yönlü olarak belirlenmiştir.

2.6 Geçiş Matrisinin Çizgelere Aktarılması

Tablo 2.7’de verilen yapının incelenmesi ve sonuçlar çıkarılması kolay değildir. Bu yüzden tablonun yönlü bir çizgeye aktarılması gelecekle ilgili yapının daha anlaşılabilir olmasını sağlayacaktır. İncelenilen tüm durumları yönlü çizgeye aktarmadan önce bir kümeleme analizi yapmak ve durumları birkaç gruba ayırarak geleneksel senaryo analizindekine benzer şekilde az sayıda senaryo elde etmek faydalı olacaktır. Ancak geleneksel senaryo analizinden farklı olarak bu kısıtlı sayıda senaryolar gelecekle ilgili birçok farklı durumu bünyelerinde barındırıyor olacaklardır. İncelenilen örnekteki toplam 29 durum 4 ana grup altında toplanmış, bir başka deyişle 4 farklı senaryo ortaya konmuştur. Bunlar, “mevcut durum”, “az miktarda hisse satışı”, “çok miktarda hisse satışı” ve “yok olma” olarak ortaya betimlenebilir.

Tablo 2.6’nın yönlü çizgeye aktarılması sırasında senaryoların ve bünyelerinde barındırdıkları gelecekle ilgili durumların daha anlaşılabilir bir yapı ortaya koyabilmesi için 3 farklı çizge oluşturulabilir. Bunlar;

- Çıkışlardan oluşan bir çizge yaratılması
- Girişlerden oluşan bir çizge yaratılması
- Sadece senaryo içi ilişkilerden oluşan bir çizge yaratılması

olarak ortaya konulabilir. Böylece karmaşık olan yapı daha anlaşılabilir ve herkesçe irdelenebilir bir hale sokulmuş olur. Yöntemin geri kalan kısmı geleneksel senaryo analizine benzer şekilde devam ettirilebilir. Yani, senaryolar ayrıntılı bir şekilde ortaya konulup stratejik planlar bu senaryolar uyarınca oluşturulabilir. Ancak geleneksel senaryo analizinden farklı olarak EFAR yaklaşımında senaryoların ayrıntılandırılması çok daha kolaydır, çünkü herbir senaryonun içinde onu daha iyi ayrıntılandırabilen çok sayıda gelecekle ilgili durum zaten mevcuttur.

2.7 Efar Yaklaşımının Zayıf Yönleri

EFAR yaklaşımı, geleneksel senaryo analizine daha dinamik bir bakış açısı kazandırmış ve senaryo oluşturulmasından sonra ortaya konması gereken stratejik hareket planları üzerinde etkin bir şekilde çalışılmasını sağlamış olsa da yöntem, bütün olarak incelendiğinde, bazı zayıf yanlar belirlenebilir.

Bunlardan ilki değişkenlerin belirlenmesinin kolay olmamasıdır (Powell ve Coyle, 1997). Konu ile ilgili bilginin istenildiği kişi, değişkenleri birbirinden ayrılması zor olacak şekilde çok yakın alanlar olarak seçebildiği gibi şirketin içinde bulunduğu durum oldukça karmaşık bir yapı içinde düşünüldüğünden kısıtlı sayıda değişkenin ortaya konması zor olabilir. Tabii bu da yöntemin ilk başındaki belki de bütünü etkileyebilecek bir aşamanın etkin bir şekilde tamamlanmaması sonucunu doğurabilir.

Bunun yanı sıra, EFAR yaklaşımı süreç tabanlı bir yaklaşım önerse de büyük ölçüde öznel bilgiye dayanır (Powell, 1997). Değişkenlere ait düzeylerin atanması tamamen çalışılan kişinin kişisel değerlendirmesine bağlıdır. Ayrıca, olurlu durumların belirlenmesi ve olanaksızların elenmesi aşamaları ile geçiş matrisinde alt ve üst limitlerin saptanması da birlikte çalışılan kişinin öznel bilgisine dayalıdır.

Ayrıca, değişkenlere verilen kodların da sayısalmış gibi değerlendirilmesi ayrı bir eksikliktir. Zira kodlar arası uzaklığı eşit varsayan bu değerlendirme, yapılan birleştirme ve durumlar arası geçişin belirlenmesi işlemlerinde kullanılmakta ve yöntemin etkinliğini azaltmaktadır.

Bu temel üç zayıf yönden ilkinin yani değişkenlerin belirlenmesinde yaşanabilecek zorluğun bilişsel haritalar yöntemi ile üstesinden gelinebileceği düşünülmüş ve bu amaçla Bölüm 3'de sözkonusu yöntem üzerinde ayrıntılı bir şekilde durulmuştur.

3 BİLİŞSEL HARİTALAR

Bu bölümde anlatılacak olan bilişsel haritalar yaklaşımı, bu tez kapsamında önerilen senaryo analiz çalışmasının ilk adımında kullanılacaktır. Benzer şekilde EFAR yaklaşımının önemli bir başlangıç adımı olan, üzerinde çalışılacak konu ile ilgili kavramların belirlenmesi konusunda da kullanılabilecek etkin bir yaklaşımdır. Bu amaçla, bilişsel haritaların ayrıntıları üzerinde durulmasının yararlı olacağına inanılmıştır.

Bilişsel haritalar bir kişi ya da grubun davranışlarına rehberlik eden, hem ölçülebilir hem de ölçülemeyen düşünce ve olaylar arasındaki ilişkilerden oluşur (Chandra ve Newburry, 1997). Kişilerin ve/veya grupların bir problemi algılama ve anlama biçimleri, birbirleri ile ilişkili öğeleri kapsayan bilişsel haritalar yardımı ile sunulabilir (Lee ve diğ., 1992). Böylece fikirler, değerler ve eğilimler ile bunların arasındaki ilişkiler, üzerinde çalışmaya olanak verecek şekilde modellenmiş olur. Bilişsel haritalar, gerçek hayatta karşılaşılan problemlerin yapılandırılması, analizi ve anlaşılması için bir yöntem olarak da düşünülebilir (Kwahk ve Kim, 1999). Çizge ve matris olmak üzere iki tür gösterimi de bünyesinde barındırdığından problemlerin anlaşılması sürecinde etkin olarak kullanılabilir. Çizge gösterimi, incelenilen sistemdeki neden-sonuç ilişkilerinin daha iyi görülmesine yardımcı olurken; matris gösterimi ise birtakım matematiksel incelemelere olanak tanır ve aynı zamanda nedensel yolların etkin bir şekilde incelenmesini sağlar.

Bilişsel haritalar, kişilerin düşünce ve inanç sisteminin, çizgeler yardımıyla sunulması olarak da nitelendirilebilir (Lee ve diğ., 1992).

Özetle, bilişsel haritaların amaçları aşağıdaki gibi sıralanabilir (Özen, 2000).

- i. En iyi çözüme ulaşabilmek,
- ii. Kişilerin düşünce yapılarının ortaya konmasını sağlayarak birden çok kişinin aynı anda anlaşılmasını sağlamak,

- iii. Tartışmaların birbirleriyle çelişen çoklu yönlerinin yapılandırılmasını sağlamak,
- iv. Kavramların çözümlenmesi için hareket planları önermek,
- v. Amaçlardan oluşan sistemde uzlaşma sağlamak,
- vi. Tartışmanın doğal rolünü bozmamak,
- vii. Kişilerin vizyonları sınırlandırılmasını engellemek,
- viii. Etkin karar vermeyi sağlamak.

Bilişsel haritalar konusunda temel iki yaklaşım vardır. Bunlar Axelrod ve Kelly tarafından belirlenen yaklaşımlardır. Axelrod'un bilişsel haritalara bakış açısı öncelikle politik karar verme alanlarında dokümantasyon araştırmalarından yola çıkmıştır. Bu yüzden de bu alanda nedensel ilişkileri ortaya koymaya yarayan bir haritalama tekniği önermiştir. Bu amaçla iyi oluşturulmuş birtakım kodlama kuralları aracılığıyla dokümanter kaynakları politik araştırmalarının resimsel gösterimi için kullanmıştır. Axelrod yaklaşımı ile bilişsel haritalar, bir konunun yapısının analizi ve ölçümlendirilmesi için güvenilir bir yoldur.

Bilişsel haritalara diğer bir yaklaşım getiren Kelly'ye göre ise bilişsel haritalar organizasyonel problem çözümünde bireylerin yorumlama sistemlerinin oluşturulması, kaydedilmesi ve analizi için kullanılır. Bu yaklaşımın temelinde kişilerin sürekli olarak yaşadıkları deneyimlerini anlamaya, yorumlamaya ve onlardan yeni bilgiler edinmeye çalışması gerçeği yani bir başka deyişle bilişsel harita kullanımı olduğu düşüncesi vardır. Bu yüzden de bilişsel haritaları kullanan analizci karar vericilerin deneyimlerini, düşüncelerini ve değerlerini ortaya koymaya çalışır.

Bilişsel haritalarda, kullanılan kavramlar düğümlerle; kavramlar arası nedensel ilişkiler ise işaretli ve yönlü oklarla gösterilir. (Lee ve diğ., 1992).

Bilişsel haritalarda, karar seçenekleri, tüm nedenler ve etkiler, amaçlar düğümlerle gösterilirler (Hwang ve Lin, 1987). Bu yaklaşımın gücü, bilişsel haritanın çizge formunda sunulmasıdır. Böylece kavramlar, ilişkiler ve genel yapı rahatça gözönünde bulunabilir.

Kişilerin bilişim süreçlerin incelenmesinde kullanılan bilişsel haritalar; dile ait özelliklerden yola çıkar, yapay zekadaki bilgi sunum tekniklerinden biri olan ağsal sunumdan yararlanır ve daha sonra bilişime ait çıkarımlar yapar (Axelrod, 1976a). Bilişsel haritalarda, kavramlar ve nedensel inançlar olmak üzere iki tip eleman vardır. Kavramlar değişkenler olarak, nedensel inançlar ise değişkenler arası ilişkiler olarak nitelendirilir.

Kavramlar 3 tip nedensel ilişki ile birbirlerine bağlanabilirler (Lee ve diğ., 1992). Nedensel ilişkilerdeki karmaşıklık derecesi, bilişsel haritanın türüne göre farklılık gösterir. Üç çeşit bilişsel harita vardır:

* Basit harita : $A \xrightarrow{+} B \xrightarrow{-} C$

* Ağırlıklı harita : $A \xrightarrow{+0.5} B \xrightarrow{-0.3} C$

* Bulanık harita : $A \xrightarrow{+fazla} B \xrightarrow{-biraz} C$

Basit formda "+", "-" ve "0" olmak üzere üç belirtim vardır. Eğer iki kavram arasında pozitif bir ilişki varsa, yani kavramlardan birinin değeri arttığında diğerinin de değeri artıyorsa, bu ilişki "+" ile; kavramlardan birinin değeri arttığında diğerinin değeri azalıyorsa "-" ile ve eğer herhangi bir ilişki yoksa "0" ile gösterilir. Eğer ilişkiler, ağırlıklı olarak gösterilirse, bu ağırlıklı haritayı oluşturur. Bulanık haritalarda ise bu ağırlıklandırma "az, biraz, çok, fazla" gibi tanımsal terimler ile yapılır.

3.1 Bilişsel Haritaların Oluşturulması

Bilişsel haritaların analizi önemli ve zor olsa da, bundan daha önemlisi bilişsel haritaların oluşum sürecidir (Axelrod, 1976a). Bilişsel bir haritayı oluşturmak için kullanılan yöntemler 4 adet gerekliliği karşılamalıdır:

- Yöntemler engelleyici olmamalıdır. Yani karar verme sürecine uygun olarak, eldeki verilerden nedensel çıkarımlar yapmak olanaklı olmalıdır.
- Bilişsel harita, gerek kavramlar gerekse aralarındaki ilişkiler açısından, haritası çıkarılan kişiye özel tanımları içermemeli ve önsel olmaksızın, bazı verilere dayanmalıdır.

- Oluşturulan bilişsel harita, karar vermenin bir değerlendirme teorisine uygun olmalı, böylece karar vericiye önerilerde bulunmak ve hatta onu eleştirmek için bile kullanılabilirdir. Yani seçenekler, amaçlar, faydalar ve ilgili kavramların tümü karar vericinin bilişsel haritasında yer almalıdır.
- Son olarak, bilişsel haritayı oluşturmak için kullanılan yöntem, karar vericinin tüm iddialarını açık bir şekilde yansıtabilmeli ve farklı araştırmacıların aynı koşullarda aynı sonuçları alabilmelerini sağlayacak kadar güvenilir olmalıdır.

Bu özellikleri sağlayan ve sağlıklı analizler yapılmasına olanak tanıyan 3 adet bilişsel harita oluşturma yöntemi vardır:

- Döküman kodlama yöntemi: İncelenilen kişiye ait düşünceleri gösteren dokümanlar (yazılar, söyleşi ya da demeçler) kullanılarak ve belirli birtakım kodlama kurallarına bağlı olarak BH'ler oluşturulur. Dökümanları kodlayarak bilişsel harita oluşturmak, hem engelleyici olmama özelliğini sağlar (yani, eldeki verilerden nedensel çıkarımlar yapılmasına olanak sağlar), hem de karar verici tarafından kullanılan kavramları tümüyle ortaya koyabilir. Ayrıca bilişsel haritaların analitik tekniklerinin kullanımı ile bilgi, karar vermenin değerlendirme teorisine uygun olur. Bir dökümanı kodlayarak bilişsel harita oluşturmak, aynı koşullarda farklı kişilerce uygulamada belirli bir kodlama kuralına sadık kalındığından aynı sonuçları vereceğinden güvenilirdir. Kodlama yapılırken ilk yapılması gereken iş, metindeki kavram değişkenlerinin ve nedensel ilişkilerin listesini yapmaktır. Daha sonra bu ilişkiler, kişinin bilişsel haritasını oluşturma sürecinde kullanılır (Önsel, 1995).

Kodlama işini yapan kişi, aralarında nedensel bir ilişki olan cümle, deyim veya paragraflarla ilgilenmelidir (Wrightson, 1976). Yani “A” öznesi, pozitif ya da negatif yönde “B” nesnesini etkiliyorsa bu ilişki kodlanmalıdır. Türkçe gramerde cümle dizilişi özne/nesne/yüklem şeklindedir. Kodlama ise neden kavramı/bağlantı/sonuç kavramı şeklinde olur. Örneğin, “Nükleer savaş tehlikesi, dünya barışını zedeliyor” cümlesinin kodlanmasında “nükleer savaş tehlikesi” neden kavramını, “dünya barışı” ise sonuç kavramını belirtir. Zedelemek sözcüğü aralarındaki ilişkinin negatif olduğunu ortaya koyar. Burada dikkat edilmesi gereken bir diğer nokta, neden ve sonuç kavramlarının değişik

değerler alabilme potansiyeline sahip değişkenler olmalarıdır. Örneğin, “Türkiye’nin gücü”, bu güç çok ya da az olabileceği için doğru bir neden/sonuç kavramı olabilir. Ancak “Türkiye”, tek başına bir değer alamayacağı için doğru oluşturulmuş bir kavram değildir.

Döküman kodlarken düşülebilecek en yakın tehlike, kodlayıcının, özellikle de konuşmacı ile aynı görüşleri paylaşıyorsa, taraflı davranmasıdır. Yani, yazıda/konuşmada olmayan bazı ilişkileri eklemek ya da kendi görüşlerini de kodlamaya aktarmak gibi dökümana sadık kalınmadan yanlış bir şekilde harita oluşturulabilir. Yöntemin diğer bir dezavantajı da incelenilen kişinin görüşlerinin net ve/veya tutarlı olmamasıdır. Bu durumda birden çok dokümandan yararlanmak, görüşlere netlik kazandırmak için bir çözüm yolu olabilir.

- Anket yöntemi: Özellikle grupların BH’lerinin oluşturulmasında, kişilere anket formu gönderilerek uygulanır. Bilişsel harita oluşturmanın bir diğer yöntemi, nedensel bağları belirleyecek konumda olan kişilere bir anket formu yollamaktır (Hwang ve Lin, 1987). En temel üstünlüğü, konu ile ilgili uzmanların kişisel görüşlerinin biraraya toplanması ve dolayısıyla oldukça geniş bir bilgi tabanı elde edilebilmesidir. Anket yöntemi ile bilişsel harita oluşturmak için izlenmesi gereken süreç aşağıda verilmiştir (Roberts, 1976):

1.Aşama: Uzmanlardan, haritası çıkarılmak istenen konu ile ilgili akıllarına gelen tüm kavramları ve ilişkileri belirlemeleri istenir. Uzmanlar seçilirken konu hakkında geniş bir bilgi sahibi olmaları ve farklı disiplinleri temsil etmeleri istenir. Muhakkak konunun özel uzmanı olmaları gerekmez. Uzmanlardan yanıt olarak gelen değişkenler derlenir ve eğer çok sayıda iseler gruplandırılırlar.

2.Aşama: Derlenen ve gruplandırılan değişkenler uzmanlara gönderilir. Değişken sayısını kısıtlamak için uzmanlardan her grup içinde yer alan değişkenleri önem sırasına dizmeleri istenir. Bu aşamada, karşılaştırmaya olanak tanınması için hem “tüm önem” sıralaması hem de “görelî önem” sıralaması kullanılır. Tüm önem sıralaması, 1-önemli değil, 7-çok önemli olmak üzere 7 üzerinden yapılır ve değişkenlerin genel önem derecelerinin saptanması beklenir. Görelî önemde ise 100’lük bir ölçek kullanılır ve değişkenlerin ilgili gruptaki diğer değişkenlere göre olan önemleri belirlenir. Bu yapılırken grup içindeki en önemli görünen

değişkene 100 verilir ve diğer tüm değişkenler buna göre derecelendirilir. Uzmanlardan gelen yanıtlar dikkate alınarak tüm önem ortalamayı (medyanı) ve göreceli önem geometrik ortalaması hesap edilir. Eldeki veriler uyarınca, değişkenleri belirlemek için çeşitli yöntemler kullanılabilir:

- Her gruptan tüm ve göreceli önemleri en yüksek olan bir ya da iki değişken seçilebilir.
- Tüm önem sıralamasına göre, 6 veya 7 derecesini alan en az bir değişkenin bulunduğu gruplardan bir ya da iki değişken seçilir. Bu yöntemde her grubun mutlaka temsil edilme zorunluluğu yoktur.
- Gruba bakmaksızın tüm önemi 6 ya da 7 olan tüm değişkenler seçilebilir.

Yukarıdaki yöntemler yardımı ile eldeki tüm değişkenler belirli bir sayıya indirgenmiş olur.

3.Aşama: Bir önceki aşamada elde edilmiş olan değişkenler ikili olarak düzenlenip uzmanlara geri gönderilir ve ikili karşılaştırmalar yaparak birbirlerine olan etkilerinin (eğer varsa) pozitif ya da negatif olup olmadığının belirlenmesi istenir. Gelen yanıtlar değerlendirilir. Eğer verilen işaretlerde uzmanlar arası görüş birliği yoksa, uzmanların %60'nın verdiği işaret doğru kabul edilir ve bilişsel harita eldeki veriler uyarınca oluşturulur.

- Görüşmeler: Döküman kodlama ile anket yöntemlerinin karması olarak düşünülebilir. Bilişsel harita oluşturma'nın üçüncü bir yolu, açık sonlu (open-ended) sorular yardımı ile, belirlenen uzmanlar ile görüşmeler yapmaktır (Axelrod, 1976a). Haritayı oluşturan kişiye, veri kaynağı ile dolaysız ve etkin olarak karşılıklı etkileşim sağlama olanağı vermesi en büyük avantajıdır.

3.2 Bilişsel Haritalarda Matematiksel Yapı

Bilişsel haritaların oluşturulma aşamasında, neden ve sonuç değişkenleri aynı olan tüm iddiaların, kesişimleri alınarak tek bir nedensel ilişkiye indirgenecek şekilde birleştirilmeleri gerekir (Axelrod, 1976b).

Örneğin + ve +, +'dır. Yani bir kişi, "A, B'ye zarar vermez" ve "A, B'yi destekler" demişse, bu ilişki bilişsel haritaya "A, B'yi destekler" şeklinde yansımalıdır. Başka bir örnek olarak, + ve -'nin kesişimi etkisi belirsiz ilişkileri yansıtan "a" ile gösterilir. Yani, "C, D'yi destekler" ve "C, D'ye zarar verir" denmişse, bu, haritada etkisi belirsiz olarak düşünülmelidir.

Tüm değişkenlerin arasındaki ilişkiler kodlanıp, bilişsel harita oluşturulduktan sonra, aynı yollar (paths) üzerindeki ilişkilerin dolaylı etkileri sözkonusu olur. Örneğin, A'dan B'ye artı bir ok, B'den C'ye başka bir artı ok varsa bu, A'dan C'ye de artı bir ok olduğu sonucunu doğurur. Sıra dahilindeki dolaysız ilişkilerin dolaylı etkilerini saptamak için birleştirilmeleri, çarpma işlemi olarak adlandırılır. Eğer okların sayısal değerleri biliniyorsa sıradan çarpma işlemi etkiyi saptamak için yeterlidir; ancak sadece işaretleri biliniyorsa, "x" herhangi bir etki türü olmak üzere aşağıda verilen çarpma kuralları kullanılmalıdır:

$$(i) (+)*(x) = x \quad (3.1)$$

$$(ii) (0)*(x) = 0 \quad (3.2)$$

$$(iii) (-)*(-) = + \quad (3.3)$$

(iv) Çarpma, toplama üzerinde dağılır, yani:

$$(-)*(⊖) = (-)*(-∪0) = ((-)*(-))∪((-)*(0)) = (+)∪(0) = ⊖ \quad (3.4)$$

$$(v) \text{ Toplama simetri özelliğine sahiptir, yani: } (⊖)*(-) = (-)*(⊖) \quad (3.5)$$

Bilişsel haritalar incelenirken dikkat edilmesi gerekli en önemli noktalardan biri, aynı neden ve sonuç kavramları arasındaki farklı yolların yaratacağı etkilerdir. Bu durumda sözkonusu olan farklı etkiler aşağıda belirtilen kurallar doğrultusunda toplanır:

$$(i) (0)+(x) = x \quad (3.6)$$

$$(ii)(+)+(+) = + \quad (3.7)$$

$$(iii) (-)+(-) = - \quad (3.8)$$

$$(iv) (+)+(-) = U \quad (3.9)$$

(v) Toplama birleşim üzerinde dağılır.

(vi) Toplama simetriktir.

3.3 Bilişsel Haritaların Özellikleri

Bilişsel haritaların özelliklerini ortaya koyan 4 problem tipi vardır (Hwang ve Lin,1987). Bunlar, kişinin kendi bilişsel haritası ile ne yapmak istediğine bağlı olarak farklılık gösterirler.

- Karar Verme Problemi: Bir veya daha çok karar değişkeni ile bir fayda değişkeni olan bir bilişsel harita verildiğinde, problem, hangi seçeneklerin elenip, hangi seçeneklerin kabul edileceğine karar vermektir. Bunun için, bilişsel haritanın oluşturulmasından sonra fayda-strateji matrisinin oluşturulması ve sözkonusu matristeki faydaları enbüyükleyecek seçeneklerin öncelik sırasına göre belirlenmesi gereklidir (Önsel, 1995). Fayda değişkeni üzerinde pozitif bir etkisi olan seçenekler kabul edilip, diğerleri red edilir (Hwang ve Lin,1987).
- Kestirim Problemi: Bilişsel haritadaki bazı değişkenlerde artış ve/veya azalış olduğunda; problem, haritanın diğer değişkenlerinin bu değişiklikten nasıl etkileneceğinin tespiti. Kestirim problemi, karar verme probleminin özel bir durumu olarak da düşünülebilir. Bilişsel haritanın oluşturulmasından sonra incelenen kavramın etkilediği tüm kavramların belirlenmesi ve etkilerinin saptanması gereklidir (Önsel, 1995).
- Anlatım Problemi: Bazı düğümlerinde değişiklikler gözlenen bir bilişsel harita söz konusu olduğunda; problem bu değişimler ile ilgili hangi açıklamaların yapılabileceğidir (Hwang ve Lin,1987). Bu durumda kestirim problemi tersinden düşünülmelidir. Yani, bilişsel haritanın oluşturulmasından sonra incelenilecek kavrama etki eden tüm kavramların belirlenmesi ve etkilerinin saptanması gereklidir (Önsel, 1995). Eğer sözkonusu kavrama herhangi bir kavramdan gelen tüm yollar pozitif ise, toplam etkinin pozitif; negatif ise toplam etkinin negatif

olduğu söylenebilir. Ancak etkiler pozitif ve negatiflik arasında değişim gösteriyorsa, sonuç belirsizdir.

- Strateji Problemi: Bilişsel bir haritada, herhangi bir değişkenin işaretini değiştirmek önemli birtakım değişimlere yol açabilir (Hwang ve Lin,1987). Örneğin istenmeyen bir seçeneği, istenebilir bir seçeneğe dönüştürmek için nedensel bağlarda hangi değişikliklerin yapılması gerektiği incelenebilir.

Bu 4 tip problemin de sağlıklı bir şekilde çözüme ulaştırılabilmesi için bilişsel haritanın kişi ve/veya grubun düşünce yapısını tam olarak ortaya koyacak şekilde düzenlenmiş olması gerekir ki, bilişsel haritanın bazı zayıf yönleri bunu kısıtlayabilir.

Bunlardan ilki bilişsel haritası oluşturulacak olan kişinin samimiyetsiz olma olasılığıdır. Örneğin bir politikacının halka verdiği demeçlerden oluşturulacak olan bir bilişsel haritanın, o politikacının o konu ile ilgili tüm düşüncelerini tam olarak yansıtmaması beklenemez. Ayrıca neden-sonuç ilişkisine dayanmayan bazı önemli noktalar da olabilir, fakat nedensel kavramlar üzerine kurulu olan bilişsel haritalar bu tip noktaların ortaya konmasına izin verecek kadar esnek değildirler. Sonuncu, fakat en önemli kısıt ise, bir noktaya giden ve farklı toplam etkilere sahip birden çok yol olma durumunda, sonucun kesin olarak belirlenememesidir.

Bilişsel haritaların etkin olarak kullanılabildiği problemlerin temel özellikleri aşağıdaki gibi özetlenebilir (Özen, 2000)

- i. Problem daha önce nitel bazı fikirlerle tanımlanmışsa bilişsel haritalar mükemmel bir başlama noktasıdır. Bazı durumlarda nitel problemlerin gelecekteki herhangi bir zamanda daha sayısal olacağına dair bir beklenti vardır. Problemlerin yapılandırılması bu gibi durumlarda oldukça kritik öneme sahiptir.
- ii. İncelenilen problem bir dizi önemli ve farklı görüşü bünyesinde barındırıyorsa, bilişsel haritalar bu zenginliğin ortaya konması ve ilgili tüm grupların birlikte çalışmasına olanak tanıyan yeni bir vizyon oluşturulması için çok iyi bir yoldur.
- iii. Problem stratejik bir yapıya sahip ise ve gelecek hakkında öznel görüşleri içeriğinde bulunduruyorsa, bilişsel haritalar gelecekle ilgili fikirleri geliştirmek, test etmek ve yönetmek için uygun bir yoldur.

- iv. İncelenilen konu, değişik grupların bağımsızlığına çalışmasını gerektiren bir dizi projenin belirlenmesini gerektiriyorsa, bilişsel haritalar bunların belirlenmesinde kusursuz bir yoldur.

3.4 Bilişsel Haritaların Analizi


Bilişsel haritaların incelenmesi ve özellikle politik tercihlerin belirlenip, karar vericiye yardım edilebilmesi için ilk önce haritadaki ilişkilerin komşuluk matrisine (K) dönüştürülmeleri gerekir (Nozicka ve diğ., 1976). Örnek bir harita ve ilgili komşuluk matrisi Şekil 3.1 ve Tablo 3.1’de verilmiştir.

Komşuluk matrisi, önemli bir takım özellikleri bünyesinde barındırır. i.satırdaki elemanların mutlak değer toplamı; i’nin çıkış derecesini(çd) verir ki bu da “i” kavramından dolaysız bir şekilde etkilenen kavram sayısını belirtir. Benzer bir biçimde, i.sütundaki elemanların mutlak toplamı; i’nin giriş derecesini (gd) verir ki bu da “i” kavramını dolaysız bir şekilde etkileyen kavramların sayısını belirtir. “i” kavramına ait olan çd ve gd’lerin toplamı ise bilişsel merkezilik derecesinin ölçümünü sağlayan, i’nin toplam derecesini(td) belirtir. Matematiksel olarak bu ilişkiler “i” incelenilen satır ve sütundaki ilgili eleman ve “j” de toplam değişken sayısı olmak üzere, aşağıdaki gibi gösterilebilir:

$$gd(i)=\sum k_{ij} \quad (3.10)$$

$$\çd(i)=\sum k_{ji} \quad (3.11)$$

$$td(i)=gd(i)+\çd(i) \quad (3.12)$$



Şekil 3.1 Örnek Bir Bilişsel Harita (Nozicka ve diğ. 1976, s.350)

Bilişsel merkezilik, örneğe uygulandığına, en merkezi kavramların en yüksek toplam dereceye sahip olan (4;2+2 ve 1+3) 5. ve 9. kavramlar olduğu görülür. Yani bu iki kavram haritanın en merkezi kavramlarıdır denilebilir.

Tablo 3.1 Komşuluk Matrisi (Nozicka ve diğ. 1976, s.350)

	1	2	3	4	5	6	7	8	9	10	11	Mutlak toplam
1	0	0	0	1	0	0	0	0	0	0	0	1
2	0	0	0	0	0	0	0	0	-1	0	0	1
3	0	0	0	1	-1	0	0	0	0	0	0	2
4	0	0	0	0	1	0	0	0	0	0	0	1
5	0	0	0	0	0	1	0	0	1	0	0	2
6	0	0	0	0	0	0	0	0	0	1	0	1
7	0	0	0	0	0	0	0	1	0	0	0	1
8	0	0	0	0	0	0	0	0	1	0	0	1
9	0	0	0	0	0	0	0	0	0	0	1	1
10	0	0	0	0	0	0	0	0	0	0	0	0
11	0	0	0	0	0	0	0	0	0	0	0	0
Mutlak toplam	0	0	0	2	2	1	0	1	3	1	1	

Komşuluk matrisinden kolaylıkla ulaşılabilirlik matrisine (U) geçiş yapılabilir. Komşuluk matrisi sadece kavramlar arasındaki dolaysız bağlantıları gösterebildiği halde; ulaşılabilirlik matrisi dolaylı ilişkileri de ortaya koyabilme özelliğine sahiptir.

Ulaşılabilirlik matrisi; " $U = K + K^2 + K^3 + \dots + K^{n-1}$ " olarak hesaplanabildiği gibi harita üzerinden gidilerek de oluşturulabilir. Genelde o kadar uzun yollar pek olmadığı için (n-1). üssüne kadar hesap yapmak gerekmez. K^m 'in 0 olduğu m üssüne kadar hesap etmek yeterlidir.

Ulaşılabilirlik matrisinin satır ve sütun mutlak toplamaları, komşuluk matrisindekine benzer bir şekilde yorumlandırılır. Satır toplamaları ilgili elemandan ulaşılacak tüm kavramları gösterirken; sütun toplamı ilgili elemana ulaşabilen tüm kavramları gösterir.

3.4.1 BH'lerin Analizinde Döngüler

Bilişsel haritalarda döngülerin varlığı haritada dinamik bir yapı olduğunun en temel göstergesidir (Eden ve diğ., 1992). Ancak, döngülerin varlığı, haritaların üzerinde yapılacak her analizi etkileyeceğinden, dikkat edilmesi gereken bir unsurdur.

Özellikle anket yöntemi ve görüşme yöntemi ile oluşturulan bilişsel haritaların döngülere sahip olması sık rastlanılan ve zor başaakılan bir durumdur.

Wang'ın (1992) ortaya koyduğu yöntemle bilişsel haritalarda varolabilecek döngülerle uğraşmak kolaylaşmış ve daha da önemlisi, bilişsel haritalardan daha ileriki analizler için yararlanmak olanağı ortaya çıkmıştır.

Sözkonusu yöntemde bilişsel haritaların komşuluk matrisinde yer alan değerler ilgili iki değişkenin kuvveti (w_{ij}) olarak tanımlanmıştır. Ancak eğer bilişsel haritalar basit formda oluşturulmamışlarsa, komşuluk matrislerindeki değerlerin -1 , 0 ya da $+1$ 'den farklı olabileceği de açıktır. Bu değerleri yöntemde kullanabilmek için T_i , i faktörü için eşik değeri olmak üzere, aşağıdaki gibi bir dönüşüm uygundur:

$$w_{ij}=+1 \quad \text{eğer } w_{ij}'\text{'nin kuvveti} > T_i$$

$$w_{ij}=0 \quad \text{eğer } -T_i \leq w_{ij}'\text{'nin kuvveti} \leq T_i$$

$$w_{ij}=-1 \quad \text{eğer } w_{ij}'\text{'nin kuvveti} < -T_i$$

Burada eşik değeri; iki değişken arasındaki ilişkinin belirli bir değerin üstünde olabilecek kadar büyük olmaması durumunda sözkonusu ilişkiyi dikkate almamak için geliştirilmiş bir değerdir.

Komşuluk matrisi Tablo 3.2'de verilen bir örnek üzerinde durmak gerekirse, sözkonusu haritanın ağırlıklı yapıda olan bilişsel haritasının öncelikle yukarıdaki basit forma dönüştürme işlemine tabii tutulması gerekliliği açıktır.

Tablo 3.2 Örnek bir Komşuluk Matrisi (Wang, 1992, s.545)

0	0	0	2.37	2.12	-2.24	0	0
0	0	0	0	0	0	0.99	0
0	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0
0	0	0	0.11	0	0	0	0
0	0	0	0	0	0	0	0
0	0	0	0	0	0.99	0	0
0	0	0	0	0	2.27	1.56	0

T_i eşik değeri 0 olarak seçildiğinde basit forma dönüştürülen komşuluk matrisi Tablo 3.3'deki hali alır.

Tablo 3.3 Basit Forma Dönüştürülmüş Komşuluk Matrisi (Wang, 1992, s.546)

0	0	0	1	1	-1	0	0
0	0	0	0	0	0	1	0
0	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0
0	0	0	1	0	0	0	0
0	0	0	0	0	0	0	0
0	0	0	0	0	1	0	0
0	0	0	0	0	1	1	0

Bu dönüşüm, eğer gerekiyorsa, yapıldıktan sonra oluşturulan model üzerindeki olası etkisi incelenecek olan, sözkonusu girdinin de (X_i) aşağıdaki gibi ortaya konması gereklidir.

$$X=(x_1, x_2, \dots, x_m) \quad i=1, \dots, m$$

$X_i = +1$ eğer i faktörü üzerinde pozitif bir etki varsa.

$X_i = 0$ eğer i faktörü üzerinde etki yoksa.

$X_i = -1$ eğer i faktörü üzerinde negatif bir etki varsa.

İncelenen örnekte 1 numaralı değişkendeki bir değişikliğin sistemi nasıl etkileyeceğinin incelenmesi için $t=0$ zamanında

$$X_1(t=0)=(1 \ 0 \ 0 \ 0 \ 0 \ 0 \ 0 \ 0)$$

olmalıdır. Böylece diğer tüm değişkenler sıfırken yani onlar üzerinde bir değişim yokken sadece 1 numaralı değişkenin sistemi ne yönde etkileyeceği saptanabilir. Sistem bunun karşılığında $(t+1)$ zamanında

$Y(t+1)=(y_1, y_2, \dots, y_m)$ gibi bir çıktı ile karşılık verir. Burada ağırlık fonksiyonu $W(i)$ ($i=1 \dots m$), komşuluk matrisinin i .sütunu olmak üzere; y_i

$y_i(t+1) = +1$ eğer $X(t)W(t) > T_i$

$y_i(t+1) = 0$ eğer $T_i \leq X(t)W(t) \leq T_i$

$y_i(t+1) = -1$ eğer $X(t)W(t) < T_i$

şeklinde ifade edilebilir.

Örnekteki değişikliğin nasıl etki edeceğini tespit etmek için de yukarıdaki işlem yerine getirildiğinde;

$$Y_1(t=1)=(0\ 0\ 0\ 1\ 1\ -1\ 0\ 0)$$

vektörü elde edilir.

t+1 zamanındaki girdi değeri ise, t+1'deki çıktılar ile, t zamanında beslenen girdinin toplamıdır.

$$x_i(t+1)=+1 \quad \text{eğer}[y_i(t+1)+x_i(t)]\geq 1;$$

$$x_i(t+1)=0 \quad \text{eğer}[y_i(t+1)+x_i(t)]=0;$$

$$x_i(t+1)=-1 \quad \text{eğer}[y_i(t+1)+x_i(t)]\leq -1;$$

olmak üzere;

$$X(t+1)=Y(t+1) + X(t) \quad (3.13)$$

olarak ifade edilir.

Örnek durum için $X_1(t=1)=(1\ 0\ 0\ 1\ 1\ -1\ 0\ 0)$ halini alır. Buna karşılık gelen çıktı ise;

$$Y_1(t=2)=(0\ 0\ 0\ 2\ 1\ -1\ 0\ 0) \text{ olur.}$$

Çıktılar döngüden kurtulup sürekli aynı değeri üretinceye dek yani bir denge noktasına gelinceye dek bu işlemlere devam edilir. Ağ tarafından ardı ardına aynı iki çıktı üretildiğinde döngüleri de gözönünde bulundurarak çalışan ama tutarlı bir çıktı üreten bu analiz tamamlanmış olur.

Örnek durumda dengeye bir sonraki adımda ulaşılır:

$$Y_1(t=3)=(0\ 0\ 0\ 2\ 1\ -1\ 0\ 0)$$

Böylece 1 numaralı değişkende meydana gelen bir değişikliğin uzun vadede 4, 5 ve 6 numaralı değişkenleri etkileyeceği sonucuna varılmış olur.

Bu yöntem bilişsel haritaların analizinde genellikle karşılaşılan bir problem olan döngüleri, analize olanak tanıyacak şekilde incelemeye izin verdiği için özellikle

önemlidir. Bu tez kapsamında da detayları 6.Bölümde anlatılacak olan uygulama kısmında uzmanların döngülere sahip olan bilişsel haritaları bu yöntemle incelenmiş ve en merkezi değişkenlerde meydana gelen herhangi bir değişikliğin diğer değişkenleri nasıl etkileyeceği, varolan yoğun döngülere rağmen analiz edilebilmiştir.

Ayrıca, bilişsel haritaların yanısıra öznel bilgiye gereksinimin en aza indirgenmesini sağlayacak şekilde yapay sinir ağlarından da yararlanılabileceği ve böylece senaryo analizine dinamizm kazandırma hedefine daha etkin bir şekilde ulaşılabileceği düşünülmüştür. Bu amaç doğrultusunda Bölüm 4’de yapay sinir ağları üzerinde durulmuştur.



4 YAPAY SİNİR AĞLARI

Bu tez kapsamında, senaryo analizi sürecine yeni ve dinamik bir boyut kazandırma hedefinden hareketle önerilen yaklaşımın çeşitli aşamalarında yapay sinir ağlarından yararlanılmasının faydalı olacağı düşünülmüştür. Bu bölümde, yapay sinir ağlarından bahsedilecek ve tez kapsamında kullanılan çeşitleri üzerinde ayrıntılı olarak durulacaktır.

Beyindeki gerçek sinir hücrelerinin ağsal yapılarının modellenmesi amacıyla ortaya çıkan yapay sinir ağlarının uygulama alanları bilgisayar bilimi ve mühendislik üzerinde yoğunlaşmıştır (Hertz ve diğ., 1991). Ancak yapay sinir ağları özellikle sağladıkları yüksek hız nedeni ile, son yıllarda bilgisayar bilimlerinin yanı sıra mühendislik, ekonomi, psikoloji gibi birçok farklı alanda kullanılan bir yöntem olarak karşımıza çıkmaktadır (Kuo ve diğ., 2001). Yapay sinir ağlarının başarılı uygulamalarına literatürde hisse senedi fiyatlarının tahminlerinde, kalite kontrol gibi üretim problemlerinde, sınıflama ve optimizasyon problemleri ile çok ölçütlü karar verme problemlerinde rastlanılabilir (Hardgrave ve diğ., 1994; Zahedi, 1991). İstatistik alanında kullanımları ise üç ana konu üzerinde yoğunlaşır (Sharda, 1994). Bunlar regresyon analizi, zaman serisi tahminleri ve sınıflama olarak ortaya konulabilir. Bu yüzden de yapay sinir ağları regresyon, diskriminant analizi, lojistik regresyon ya da tahmin yaklaşımlarının kullanıldığı tüm problemlere rahatlıkla uygulanabilir.

Yapay sinir ağları, insan beynindeki sinir hücrelerine benzer şekilde, yoğun olarak birbirine bağlı basit işlem birimlerinden oluşur (Tang ve Fishwick, 1993). Yoğun bağlantıları nedeni ile yüksek hız, donanım hatalarına dayanıklılık, farklı veri tipleriyle çalışabilme, öğrenme ve adapte olabilme gibi özelliklere sahiptirler. Tez kapsamında önerilen yöntemin ilk aşaması olan değişkenlerin belirlenmesi ve dördüncü aşaması olan kümeleme analizinin yapılması aşamalarında yapay sinir ağlarının etkin olarak kullanılabileceği düşünülmüştür.

Gately'ye (1996) göre yapay sinir ağıları, örnekleri sınıflandırmak ya da geçmiş deneyimlere dayalı tahminlerde bulunup, kararlar vermek için kullanılan ve insan beynini taklit eden bir yazılım programıdır. İnsan beyni beş duyusundan aldığı verilerle hareket ederken, yapay sinir ağıları veri gruplarındaki girdileri kullanır.


Biyolojik bir sinir hücresi, kaba bir hesaplama becerisine sahip tek bir hücreden oluşur (Masters, 1993). Bir ya da daha çok girdi tarafından uyarılır ve diğer sinir hücrelerine iletmek üzere bir çıktı yaratır. Oluşan çıktı, her bir girdinin kuvvetine ve girdilerin sözkonusu hücre ile olan bağlantılarının yapısına bağlıdır. Girdiler ve çıktılar arası yapı oldukça karmaşık olabilir. Tek bir sinir hücresi, girdilerin ağırlıklı toplamı olarak modellendiği gibi, karmaşık diferansiyel denklemler topluluğu olarak da modellenabilir. Hücreler arası bağlantılar ise bilginin aktığı katmanlarla düzenlenirler. Hücreler arası bağlantıların kuvveti yani ağırlıklar yapay sinir ağıının amacına göre değişiklik gösterir (Gately, 1996). Zaten, mimarisi bir başka deyişle yapısı aynı olan iki yapay sinir ağını birbirinden ayıran en temel özellik sözkonusu bu ağırlıklardır. Yapay sinir ağlarında da tıpkı beyinde olduğu gibi tek bir hücrenin davranışı basit olsa da hücrelerden oluşan bir sistemin davranışı oldukça karmaşık olabilir (Hart; 1992).

Bulanık verilere dayalı çıkarımlar yapılması gerektiğinde, veriler matematiksel anlamda kaotik olduğunda ya da doğrusal olmadıklarında, diğer yöntemlere kıyasla, yapay sinir ağları daha iyi sonuçlar verirler (Gately, 1996). Genel yaklaşım; geleneksel modelleme yöntemleri veya istatistiksel yöntemlerle çözülebilen problemlerin yapay sinir ağları ile daha etkin çözülebileceğidir. Sharda'nın (1994) yapay sinir ağlarının uygulamaları ile ilgili yapmış olduğu bir çalışma; yapay sinir ağlarının geleneksel istatistik tekniklerine kıyasla %71 oranında (42 çalışmanın 30'u) daha başarılı olduklarını ortaya koymuştur.

Sinir ağları geleneksel bilgisayar uygulamalarından birçok yerde ayrılır (Hawley ve diğ., 1990). Sinir ağları geleneksel anlamda "programlanmazlar". Tanınacak durum veya nesnelerle ilgili nitel tanımlamalar ya da benzer nesneleri birbirinden ayırmak için mantıksal kriterler içermezler. Bunun yerine, gerçek durumu yansıtan tekrarlı birçok örneğin kendilerine sunulması yoluyla veriler arasındaki ilişkileri "keşfederler". Diğer bir deyişle, yapay sinir ağları adaptasyon yolu ile öğrenirler.

4.1 Yapay Sinir Ağlarının Temel Yapısı

Yapay sinir ağlarının birçok çeşidi olsa da genel yapı Şekil 4.1’de gösterildiği gibidir (Masters,1993). Bir ya da genellikle daha çok girdi söz konusudur. Bunlar girdi sinir hücreleri olarak adlandırılırlar. Girdi sinir hücreleri hipotetiklerdir, yani girdilerine herhangi bir işlem yapmazlar, bu yüzden de girdilerine eşit değerde çıktılar üretirler. Ağın sonuçlarını ise bir ya da daha fazla sayıdaki çıktı hücreleri sağlar. Hipotetik girdi sinir hücrelerinin aksine çıktı hücreleri gerçektirler. Girdi ve çıktı sinir hücreleri birbirlerine bir “kara kutu” aracılığı ile bağlıdırlar. Zaten yapay sinir ağlarının modelini de bu kara kutunun yapısı belirler. Ancak bu gösterim genel olsa da tek değildir. Bazı modeller bu aracıyı ortadan kaldırıp doğrudan girdi hücrelerini çıktı hücrelerine bağladığı gibi, bazıları da araya birden çok sayıda aracı katman koyabilirler.




Şekil 4.1 Yapay Sinir Ağlarının Temel Yapısı(Masters, 1993, s.9)

Genel gösterimi yukarıdaki gibi olan yapay sinir ağları, birbirlerine yönlü ve ağırlıklandırılmış bağlantılar ile bağlı belirli sayıdaki işlem birimlerinden (sinir hücreleri) oluşurlar (Masson ve Wang, 1990). Girdi sinyalleri hücrenin bağlantılarından alınır, bu sinyallere ağırlıklar atanır ve toplanır(Hawley ve Johnson, 1994). Sonuç "transfer fonksiyonu" olarak adlandırılan bir fonksiyona tabi tutulur. Ancak yapay sinir ağlarında tekil hücreler çok basit kurallara göre hareket ederken, toplu davranışın oldukça karmaşık olduğu unutulmamalıdır (Chaudhury ve diğ., 1994).

Yapay sinir ağlarının gösterimi, düğümlerin hücreleri, bağlantıların da hücreler arası ilişkileri gösterdiği ağırlıklı yönlü çizgelerle ortaya konulabilir (Tam ve Kiang, 1992). İki katmanlı ileri-beslemeli ağlara bir örnek Şekil 4.2’de verilmiştir (Tang ve

Fishwick, 1993). Burada 3 girdi sinir hücresi, 4 gizli sinir hücresi ve 3 tane de çıktı sinir hücresi bulunmaktadır.



Şekil 4.2 Örnek Bir Yapay Sinir Ağı (Tang ve Fishwick, 1992, s.375)

Şekil 4.2’de verilen örnek yapay sinir ağı üç düzeyli olarak nitelendirilir. Düzey, diğer düzeylerdeki hücrelerle bağlantılı olan ancak kendi arasında bağlantılı olmayan hücreler topluluğu olarak tanımlanabilir(Luk ve diğ., 2001).

Sonuç olarak yapay sinir ağı modelinin;

- Hücre değerlerinin bağlantılar aracılığı ile hücreler arasında geçebildiğini;
- Her bir bağlantının bir ağırlığı olduğunu ve ağıdaki hücre değerlerinin bu ağırlıklar ile çarpılarak iletildiğini;
- Her bir hücrenin çıktı değerini elde etmek için girdisine bir hareket fonksiyonu uyguladığını

varsayan bir model olduğu söylenebilir (Lee ve Park, 2001).

4.2 Yapay Sinir Ağlarında Öğrenme

Yapay sinir ağlarında öğrenme süreci sayısal eğitim verilerine dayanarak ağırlık ve hata terimlerinin, yani bilinmeyenlerin değerlerinin belirlenmesi işlemidir (Lopez ve diğ., 2001).

Sinir ağları zaman içinde öğrenebildikleri için adaptif sistemlerdir (Piramuthu ve diğ., 1993). Başka bir deyişle, sinir ağları, problem çözmedeki performanslarını

geçmiş deneyimlerine dayanarak geliştirebilme özelliğine sahiptirler. Yapay sinir ağlarında bu olay "öğrenme" olarak adlandırılır. Öğrenme algoritmaları istenen çıktıları elde edebilmek için bağlantıların ağırlıklarının belirlenmesi işlemidir (Hruschka, 1993).

Yapay sinir ağlarının öğrenme süreci ödül ve ceza mekanizması olarak düşünülebilir. Sistem, bir veriye doğru bir şekilde tepki verdiğinde ağırlıklar güçlendirilir. Böylece gelecekte de benzer girdilere benzer çıktılar üretmesi sağlanmış olur. Ters şekilde, istenmeyen çıktılar ürettiğinde de ağırlıklar zayıflştırılır. Böylece, gelecekte benzer girdilere farklı tepkiler vermesi gerektiği öğretilir. Bu şekilde, istenen tür davranışlar için sistem teşvik edilirken, istenmeyenler için cezalandırılmış olur.

Masson ve Wang'a (1990) göre eğitim sürecinin amacı, istenen yapay sinir ağı yapısını elde etmek için ağırlıkların belirli değerler almasını sağlamaktır. Diğer bir deyişle, eğitim; ağırlıklar uzayında yapılan bir aramadır.

Bir sinir ağı temelde üç değişik türde öğrenebilir (Masters, 1993). Gözetimli, gözetimsiz ve karma öğrenme olarak adlandırılan bu öğrenme türleri ilerleyen bölümlerde anlatılmıştır.

4.2.1 Gözetimli Öğrenme

Öğrenme türleri içinde en çok bilineni ve kullanılanı gözetimli (supervised) öğrenmedir. Yapay sinir ağına örnek oluşturmak için birçok veri toplanır. Daha sonra bu gruptan "eğitim grubu" olarak adlandırılan bir alt küme seçilir ve sözkonusu bu kümedeki örnekler ağına verilir. Her bir örnek grubu için ağına ürettiği çıktı, üretmesi istenilen çıktılarla kıyaslanır ve doğru çıktılara ulaşabilmek için ağırlıklar güncellenir. Bu güncelleme işlemi ağına çıktılarındaki hatayı azaltmaya yöneliktir. Ağına ağırlıklarının güncellenmesini de içerecek şekilde eğitim örneklerinin ağıdan bir geçişi devir (epoch) olarak adlandırılır. Eğitim devirleri etkin bir sonuca ulaşana dek sürdürülür. Sözkonusu hatanın azaltılmasına yönelik olarak ağırlıklara değerler atanması işlemi, regresyon analizindeki "parametre kestirimi"ne benzer. Regresyon analizinde de bir ya da daha çok sayıda bağımsız değişken; tek bir bağımlı değişkeni tahmin etmek için kullanılır (Masters, 1993). Ancak, regresyon analizinde doğrusallıktan uzaklaştıkça, tahmin hatası artar. Oysa, karmaşık ve doğrusal olmayan ilişkiler yapay sinir ağları yardımı ile başarı ile modellenilebilir. Yapay sinir ağlarının,

klasik regresyon analizinden diğer önemli farklılığı, değişkenler arasındaki ilişkinin türünü kendi belirlemesidir (Salchenberger ve diğ., 1992). Bunun sonucunda ise daha iyi sonuçlar vermesi beklenir çünkü değişkenlerin birbirleriyle olan ilişkileri hakkında herhangi bir varsayıma gerek duymadan verileri değerlendirir. Sonuçta ise, verilere özgü modelini, verilerin yapısına uygun olarak kendi kurar.

Veri grubunun bir alt kümesi ile ağı eğitilmesi, klasik doğrulama (validation) tekniği gereğidir. Eğitim sürecine dahil edilmeyen örnekler, ağı öğrenme etkinliğinin testi için kullanılırlar. Zira sadece eğitilen bir yapay sinir ağının doğrudan uygulamaya konması doğru değildir. Bundan önce yapay sinir ağı test edilmeli ve eğitim sürecinde ulaşılan başarıya test aşamasında da ulaşıp ulaşamadığı gözlemlenmelidir. Genellikle eğitim aşamasında çok küçük hata değerlerine ulaşmak mümkündür ancak önemli olan test aşamasında da bu değerlerin aynısı elde edilmese de onlara yaklaşabilmektir.


4.2.1.1 Algılayıcılar (Perceptrons)

Algılayıcı, 1958 yılında Rosenblatt tarafından ortaya konan ve gözetimli öğrenmeyi kullanan ilk yapay sinir ağının adıdır. Ancak biyolojik modelleri temel almış olan ve öğrenme yeteneği bulunan algılayıcının önemli bir zayıf noktası bulunuyordu. Bu da sınıflamayı gerektiren önemli bir bölüm görevi yerine getirmek için öğrenmeyi gerçekleştirilemiyor oluşuydu: (Masters, 1993). Sözkonusu sınıflama problemleri çıktı düzeyinde doğrusal ayrılabilir olmayanlardır. Bu tür problemlere verilebilecek en tipik örnek aşağıda verileri ve ilgili grafiği verilmiş olan XOR (exclusive or- ya da) problemidir. XOR problemi, girdilerden sadece bir tanesi doğruyken doğru sonuç veren diğer hallerde yanlış sonuç veren mantıksal bir ifadedir (Tam, 1991).


Şekil 4.3'deki grafik üzerinde çıktıları gruplayabilecek şekilde bir doğru çizilemez, yani çıktılar doğrusal olarak ayrılamaz ve bu yüzden de algılayıcı tarafından öğrenme gerçekleştirilemez (Masters, 1993). Oysa, Şekil 4.4'deki gibi doğrusal ayrılabilen problemler algılayıcılar tarafından rahatlıkla öğrenilebilirler.

Algılayıcıların bu önemli yetersizlikleri yapay sinir ağları çalışmalarının uzun bir süre durgunluk dönemine girmesine neden olmuştur. Daha sonra 1986 yılında Rumelhart, Hinton ve Williams tarafından yapılan araştırmaların yayınlanması ve

doğrusal ayrılabilirlikle kısıtlı olmayan çok katmanlı ileri beslemeli ağların ortaya konması ile yapay sinir ağları tekrar önem kazanmıştır.



Şekil 4.3 Doğrusal Olarak Ayrılamayan XOR Problemi (Masters, 1993, s.5)



Şekil 4.4 Doğrusal Olarak Ayrılabilen Bir Problem Örneği (Masters, 1993, s.5)

$n-1$ adet girdi hücresi olan bir algılayıcı için kullanılan öğrenme algoritması aşağıda verilmiştir (Lippmann, 1987).

Adım1. Ağırlıklara küçük ve rassal başlangıç değerlerini ata.

Adım2. Yeni girdi ve istenen çıktı değerlerini ağa ver.

Adım 3. Gerçekleşen çıktıyı aşağıdaki şekilde hesapla.

$$y(t) = f \left(\sum_{i=0}^{n-1} w_i(t)x_i(t) \right) \quad (4.1)$$

Adım 4. Ağırlıkları aşağıdaki formül uyarınca güncelle.

$$w_i(t+1) = w_i(t) + \eta[o(t) - y(t)]x_i(t) \quad (4.2)$$

Burada η , 1'den küçük pozitif bir kazanım oranı (öğrenme oranı) $o(t)$ ise çıktı için gerçekleşmesi istenen hedef değerdir. Formül gereğince, doğru çıktıya ulaşıldığında ağırlıklar değişmez ve süreç böyle bir noktada algılayıcının verilen veri yapısını öğrendiği varsayılarak sonlandırılır.


Adım 5. ikinci adıma dön.

4.2.1.2 Çok Katmanlı İleri Beslemeli (Multilayered feed forward) Ağlar

Yapay sinir ağlarının bir türü olan ileri-beslemeli ağlar iki veya daha çok katmandan oluşan işlem birimleri hiyerarşileridir (Schalkoff, 1997). İlk katman sinir ağına bilgilerin verildiği girdi hücrelerinden oluşur. Son katman ise çıktıların alındığı katmandır. Bu iki katman arasında gizli sinir hücrelerinin yer aldığı çeşitli sayıda ara katmanlar da var olabilir.

Doğrusal olarak ayrılabilen fonksiyonlar için algılayıcılar uygunken gerçek hayatta karşılaşılan birçok problemin temel özelliği olan doğrusal olarak ayrılama özelliğine sahip olanlar için çok katmanlı yapay sinir ağları kullanımı gereklidir (Piramuthu ve diğ., 1993).

Bir önceki bölümde üzerinde durulan ve algılayıcılarla çözümü olanaklı olmayan XOR problemini çözmeye elverişli üç düzeyli bir yapay sinir ağı şekil 4.5'de verilmiştir (Masters, 1993).



Şekil 4.5 XOR Problemini Çözen Yapay Sinir Ağı Yapısı (Masters, 1993, s.83)

Sözkonusu problemde ilk girdi 0, ikinci girdi 1 iken çıktının 1 olması yani çıktı sinir hücresinin tamamen uyarılmış olması beklenir. Birinci gizli sinir hücresinin ağırlıklı

toplamına lojistik fonksiyon uygulandığında;

$$f(0.0 \cdot -4.8 + 1.0 \cdot 4.6 - 2.6) = f(2) = 0.88$$

bulunur. Aynı işlem ikinci gizli sinir hücresi için yapıldığında ise;

$$f(0.0 \cdot 5.1 + 1.0 \cdot -5.2 - 3.2) = f(-8.4) = 0.0$$

bulunur. İki gizli sinir hücresinin çıktı değerleri çıktı sinir hücresi için girdi olacaktır. Böylece, çıktı sinir hücresi için sonuç hesaplandığında;

$$f(0.88 \cdot 5.9 + 0.0 \cdot 5.2 - 2.7) = f(2.5) = 0.92$$


değeri gibi tamamen uyarılmış olmaya (1.0) çok yakın bir değere ulaşılmış olduğu görülür. Benzer şekilde hesaplamalarla (1,0) girdisi için yapay sinir ağı yardımı ile 0.86; (0,0) girdisi için 0.11 ve (1,1) girdisi için de 0.10 çıktı değerlerine ulaşıldığı yani sözkonusu üç düzeyli ağı XOR problemini çözdüğü görülmüş olur.

Uygulamada bu yapıdaki yani sadece bir gizli düzeye sahip yapay sinir ağlarının sınırlı sayıda veriden oluşan fonksiyonları ve sürekli fonksiyonları öğrenebildiği görülmüştür. İkinci bir gizli düzeye gereksinim sadece genellikle sürekli ancak bazı noktalarda bu sürekliliği bozan durumlar varsa ortaya çıkabilir. Ancak yine de gerçek hayatta karşılaşılan problemlerin çoğunluğunun tek gizli düzeye çözümlenebileceği ve birden fazla gizli düzey kullanmanın öğrenmeyi yavaşlatacağı unutulmamalıdır.

Yapay sinir ağları için birçok yapı ve öğrenme algoritması ortaya konmuş olsa da içlerinde en sık kullanılanı geri yayılmalı (back-propagation) öğrenme algoritmasını kullanan ileri beslemeli yapay sinir ağlarıdır (Klein ve Rossin, 1999). Çok katmanlı ileri beslemeli yapay sinir ağları iki ya da daha çok düzeyde organize olmuş sinir hücrelerinden oluşurlar (Masters, 1993). En az birer hücreye sahip girdi ve çıktı düzeylerinin yanısıra bu iki düzeyin arasında genellikle bir, bazen daha çok “gizli” (hidden) düzey bulunur. “İleri beslemeli” terimi bilginin sadece tek yönlü aktığının bir göstergesidir. Her bir düzeyin girdileri bir önceki düzeyin çıktılarıdır ve ürettikleri çıktılar da bir sonraki düzey için girdi görevini üstlenirler. Ağdaki her bir sinir hücresinin çıktısı, sözkonusu hücrenin girdilerinin bir fonksiyonudur.

Geri yayımlı öğrenme algoritması; daha önceden hiç kullanılmamış bir verinin girdi katmanından ağa verilmesinden sonra doğru tahminin yapılması yani doğru çıktıya ulaşılması için ağırlıklarının eğitilmesidir (Chiang ve diğ., 1996). Bu eğitimin yapılabilmesi için de mutlaka her bir girdi için istenen çıktının da ağa tanıtılması gereklidir (Salchenberger ve diğ., 1992). Enküçüklenmek istenen hata, çok basit olarak ulaşmak istenen çıktı değeri ile öğrenme süreci boyunca hesaplanan, diğer bir deyişle gerçekleşen çıktı arasındaki değerdir (Chiang ve diğ., 1996; Hardgrave ve diğ., 1994). Geri yayımlı algoritmada ileri ve geri olmak üzere iki temel adım vardır. İleri adım sırasında bilinen veriler girdi katmanından ağa verilir. Her bir değişken için bir adet girdi hücresi vardır. Daha sonra gizli katmandaki her bir hücre için girdi hücreleri ile ilgili ağırlıkların çarpımının toplamından oluşan bir değişken hesaplanır.

Şekil 4.6'de tek bir hücrenin şematik gösterimi verilmiştir (Masters, 1993). 0'dan $n-1$ 'e dek numaralanmış n adet girdisi ve değeri 1'e eşit hata terimine sahiptir. Bir hücre ile hata hücre arasındaki fark, hata hücrenin değerinin her zaman 1'e eşit olması ve hiç girdi hücresine sahip olmaması dolayısı ile diğer hücrelerden etkilenmemesidir. Sözkonusu hücre, $n+1$ ağırlık teriminin her bir girdi ile çarpılması ve bir çıktı üretmek üzere bu ağırlıklı toplama bir hareket fonksiyonu uygulanması ile karakterize edilebilir.



Şekil 4.6 Yapay Bir Sinir Hücresi (Masters, 1993, s.78)

Benzer şekilde birçok hücreden oluşan, bir yapay sinir ağı için kullanılan matematiksel ifadeler aşağıda verilmiştir (Hertz ve diğ., 1991). "f" hareket fonksiyonunu, " y_i " çıktı, " x_k " girdi, " v_j " gizli hücre değerlerini, " w_{jk}^1 " girdi-gizli düzeyleri arasındaki bağlantıların, " w_{ij}^2 " ise gizli-çıkı düzeyleri arasındaki bağlantıların ağırlıklarını göstermek üzere:

$$v_j^\mu = f\left(\sum_k w_{jk}^1 * x_k^\mu\right) \quad (4.3)$$

$$y_i^\mu = f\left(\sum_j w_{ij}^2 * v_j^\mu\right) = f\left(\sum_j w_{ij}^2 * f\left(\sum_k w_{jk}^1 * x_k^\mu\right)\right) \quad (4.4)$$

olarak tanımlanabilir. Eğitim setinde “p” adet örnek olduğu varsayılmış ve farklı örnekler “μ” ile gösterilmiştir. Burada hata terimleri karışıklık yaratmaması amacıyla fomülde yeralmamıştır. Aslında herbir gizli ve çıktı hücresine ait bir de hata terimi olduğu unutulmamalıdır. Hata terimlerine de formülde yerveren diğer bir gösterimle, çıktı hücresinin değeri aşağıdaki formül yardımıyla hesaplanabilir (Rodriguez ve diğ., 2000):

$$y_i^\mu = f\left(w_{oi}^2 + \sum_j w_{ij}^2 * v_j^\mu\right) = f\left(w_{oi}^2 + \sum_j w_{ij}^2 * f\left(w_{ok}^1 + \sum_k w_{jk}^1 * x_k^\mu\right)\right) \quad (4.5)$$

Sinir hücresinin çıktısını belirleyen ve doğrusal olmayan bir fonksiyon olan hareket fonksiyonu oldukça önemlidir ancak uygulamada hareket fonksiyonunun tipi ağıın genel performansına çok az etki eder (Masters, 1993). İlk yapay sinir ağları modelleri, eğer girdilerin ağırlıklı toplamı belirli bir değerin altındaysa çıktının 0 olmasını öngören basit fonksiyonlar kullanmışlardır. Oysa sözkonusu fonksiyonun doğrusal olmaması, karmaşık yapılar için gereklidir (Blum, 1992). Ayrıca türevinin alınabilir olması da oldukça yararlıdır (Masters, 1993). Mevcut modellerin çoğu sigmoid (s-tipi) fonksiyonlar kullanmaktadırlar. Sigmoid tipi fonksiyon, basit olarak, sürekli, gerçek değerli, türevi her zaman pozitif ve sınırlı bir fonksiyon olarak tanımlanabilir. En sık kullanılan sigmod tipi fonksiyonun değer aralığı 0.0 ile 1.0 arası değişen lojistik fonksiyon olduğu söylenebilir (Hart, 1992).

$$f(x) = \frac{1}{1 + e^{-x}} \quad (4.6)$$

Bu fonksiyonun en önemli özelliği türevinin alınabilir oluşudur (Masters, 1993).

$$f'(x) = f(x) * (1 - f(x)) \quad (4.7)$$

Bu konuda yapılan arařtırmalar yapay sinir aęlarında kullanılan fonksiyonun řeklinin; aęın gúcüne olan etkisinin az, öğrenme hızına olan etkisinin ise yüksek olduğunu ortaya koymuřtur.

Gizli düzeyde hareket fonksiyonu uygulanmıř olan bu deęerler de yine ilgili aęlırlıklar ile çarpılıp toplamları alınır. Böylece çıktı hücresi için bir girdi deęiřken deęeri saptanmıř olur. Daha sonra ise, yine bir hareket fonksiyonu bu deęiřkene uygulanarak çıktı hücresi için de bir çıktı deęeri elde edilmiř olur.

Geri adımda ise ulařılmak istenen hedef deęer ile ulařılan gerçek deęer arasındaki hata, çıktı hücresinden başlayarak geriye doęru aęlırlıkların düzeltilmesi için kullanılmaya bařlanır. Zira ileri beslemeli bir yapay sinir aęında öğrenme sürecinin amacı eldeki girdi-çıkıtı verilerinin yapısını en iyi řekilde öğrenecek řekilde sinir hücreleri arasındaki baęlantıların aęlırlık deęerlerinin belirlenmesidir (Stam ve dię., 1996).

Yapay sinir aęlarında geri yayılmalı öğrenme algoritması; çıktı katmanından elde edilen hata miktarının çıktı-gizli ve gizli-girdi hücre baęlantılarının aęlırlıklarının geriye doęru güncelleřtirilmesi için kullanılması üzerine kuruludur (Chiang ve dię., 1996). Dięer bir deyiřle öğrenme sürecinin amacı verilerin girdi-çıkıtı çiftleri doęrultusunda aęlırlıklar için en uygun deęerleri saptamaktır (White, 1989; Rumelhart ve dię., 1986)). Bu yüzden yapay sinir aęında üretilen çıktı $-o_i-$, öğretim hedefi $-y_i-$ ile karřılařtırılır (Hertz ve dię., 1991; Tang ve Fishwick, 1993; Battiti, 1992). Bu ařamada o_i ve y_i arasındaki farka dayalı bir performans ölçütü tanımlanmalıdır. Çok kullanılan bir performans ölçütü hata terimlerinin karelerinin toplamıdır.

$$E = \frac{1}{2} \sum_{\mu} (o_i^{\mu} - y_i^{\mu})^2 \quad (4.8)$$

Burada yine μ , örnek için; i ise çıktı birimleri için kullanılan indekstir. Daha önceki formüller yardımıyla bu hata deęerini daha açık yazmak olasıdır:

$$E = \frac{1}{2} \sum_{\mu} (o_i^{\mu} - f(\sum_j w_{ij}^2 * f(\sum_k w_{jk}^1 * x_k^{\mu})))^2 \quad (4.9)$$

Çıktı katmanından elde edilen hata; ağırlık geri-yayılır ve ağırlıklar hata fonksiyonuna olan katkıları oranında yeniden belirlenirler. Geri yayımlı öğrenme algoritması sürecinde, hata değerini en küçükleyen çözüme ulaşmak için yerine getirilmesi gereken ağırlıkların güncelleştirilmesi işlemi için ağırlık uzayında gradyan-inişi (gradient-descent) yöntemi uygulanır (Tam ve Kiang, 1992; Leu ve diğ., 2001). Her bir w_{ij} ağırlığı için ağırlık değişiminin yönü ve büyüklüğü aşağıdaki gibi ortaya konulabilir (Hertz ve diğ., 1991):

$$\Delta w_{ij} = -\eta \frac{\partial E}{\partial w_{ij}} = \eta \sum_{\mu} (o_i^{\mu} - y_i^{\mu}) * f'(\sum_j w_{ij}^2 * v_j^{\mu}) * v_j^{\mu} \quad (4.10)$$

η , tıpkı algılayıcıda olduğu gibi ağırlıkların güncelleştirilmesinde kullanılan adım büyüklüğü yani öğrenme oranıdır. Burada kullanılan öğrenme oranı, ağırlıkların değişimlerinin ne kadar büyük olacağını ortaya koyar. Formülde,

$$\delta_i^{\mu} = (o_i^{\mu} - y_i^{\mu}) * f'(\sum_j w_{ij}^2 * v_j^{\mu}) \quad (4.11)$$

olarak tanımlanırsa formül aşağıdaki son halini alır.

$$\Delta w_{ij}^2 = \eta \sum_{\mu} \delta_i^{\mu} * v_j^{\mu} \quad (4.12)$$

Algoritmada hedef, tüm girdi vektörleri tüm çıktı vektörleri ile doğru bir şekilde ilişkilendirilecek şekilde W ağırlıklarını değiştirerek E fonksiyonunu enküçükmektir (Tam ve Kiang, 1992). Bu yüzden de öğrenme süreci W ağırlıklar uzayında E amaç fonksiyonu ile ortaya konan bir enküçükleme problemi olarak düşünülmelidir. Benzer şekilde girdi-gizli düzeyi arasındaki bağlantıların ağırlıkların güncellenmesi işlemi ise aşağıdaki gibi olur. İlk adım zincir kuralı uyarınca yazılır ve yukardakine benzer işlemlerle formül son halini alır.

$$\Delta w_{jk}^1 = -\eta \frac{\partial E}{\partial w_{jk}^1} = -\eta \sum_{\mu} \frac{\partial E}{\partial v_i^{\mu}} \frac{\partial v_i^{\mu}}{\partial w_{jk}^1} \quad (4.13)$$

$$\Delta w_{jk}^1 = \eta \sum_{\mu} (o_i^{\mu} - y_i^{\mu}) * f'(\sum_l w_{lj}^2 * v_l^{\mu}) * w_{lj}^2 * f'(\sum_k w_{jk}^1 * x_k^{\mu}) * x_k^{\mu} \quad (4.14)$$

$$\Delta w_{jk}^1 = \eta \sum_{\mu} \delta_i^{\mu} * w_{lj}^2 * f'(\sum_k w_{jk}^1 * x_k^{\mu}) * x_k^{\mu} \quad (4.15)$$

$$\delta_i^{\mu} = f'(\sum_k w_{jk}^1 * x_k^{\mu}) * \sum_l w_{lj}^2 * \delta_l^{\mu} \quad (4.16)$$

olmak üzere, ağırlık değişimi

$$\Delta w_{jk}^1 = \eta \sum_{\mu} \delta_i^{\mu} * x_k^{\mu} \quad (4.17)$$

şeklinde ifade edilebilir.

4.2.1.2.1 Geri Yayılmalı Öğrenme Algoritması İçin Bir Örnek

Bu bağlamda geri-yayılma algoritmanın adımları aşağıda verilmiştir (Tang ve Fishwick, 1993). Adımların daha açık bir hal alması için de verileri Tablo 4.1'de verilen örnek bir problem üzerinden gidilmiştir. Gösterim ve hesaplamaları karmaşık bir hale getirmemek için bir gizli katmanda sadece 3 adet gizli sinir hücresi kullanılmış ve eğitim süreci sadece 12 veri ile çalışılmıştır. Söz konusu ağı yapısı Şekil 4.7'de verilmiştir.

Tablo 4.1 Örnek Problem İçin Eğitim Verileri

x1	x2	Y
0.0999999997	0.1	0.216479681
0.106963952	0.101409848	0.269622227
0.114863209	0.110744341	0.242087382
0.146580286	0.106739438	0.9
0.151168496	0.110605778	0.400492691
0.145276234	0.107683127	0.100431182
0.14332258	0.108110315	0.127459267
0.145225378	0.108159505	0.137594036
0.1513995	0.113684463	0.307738022
0.154046476	0.120194738	0.385212276
0.157818324	0.123695446	0.33884074
0.160955432	0.129758851	0.280463121


1. Başlangıç

İleri-beslemeli sinir ağını oluştur. Girdi, gizli ve çıktı sinir hücrelerinin sayılarını, belirle.

Girdi sinir hücresi sayısı: 2 (x_1 ve x_2)

Gizli sinir hücresi sayısı: 3

Çıktı sinir hücresi sayısı: 1 (y)



Şekil 4.7 Örnek Problem için Yapay Sinir Ağı Yapısı

Ağırlıkları ve hata terimini rassal olarak belirle.

$w1$ =(girdi gizli düzeyleri arasındaki bağlantı ağırlıkları)
-26.7266 -60.3548
9.8207 -78.962
14.6185 -75.7829

$b1$ =(girdi gizli düzeyleri arasındaki hata terimlerinin bağlantı ağırlıkları)
10.2207
8.2426
7.0143

$w2$ =(gizli çıktı düzeyleri arasındaki bağlantı ağırlıkları)
0.5448 0.4382 0.0341

$b2$ =(gizli çıktı düzeyleri arasındaki hata teriminin bağlantı ağırlığı)
-0.57192

$E \leq E_{dur}$ veya $n \geq n_{enb}$ gibi bir durma ölçütü belirle.

$E_{dur}=0.01$ ve $n_{enb}=100$ olsun

İterasyon sayısı=0.

2.İleri-besleme

Girdi birimi olmayan hücreler için çıktıları hesapla. n katmanlı bir ağda, p örneği için ağın çıktısı aşağıdaki gibidir.

$$o_{pk} = f\left(\sum_i w_i^{n-1} - f_k \left(\sum_m w_m^{n-2} f\left(\dots f\left(\sum_i w_i^1 x_i \right) \right) \right) \right) \quad (4.18)$$

Birinci gizli sinir hücresi ile çıktı hücresinin ilk veri grubu gözönünde tutularak girdi ve çıktı değerlerinin hesabı aşağıda yapılmış, diğer tüm değerlerin hesaplanmış hali de Tablo 4.2'de verilmiştir. Hareket fonksiyonu olarak (4.6)'da ilgili formülü verilen lojistik fonksiyon seçilmiştir. Bunun en önemli nedeni, türevinin kolay alınabilir olması nedeniyle sağladığı hesaplama kolaylığıdır.

$$G_1(\text{girdi}) = x_1 * w_{11} + x_2 * w_{12} + b_1 = 0.9999 * (-26.7266) + 0.1 * (-60.3548) + 10.2207 = 1.5125$$

$$G_1(\text{çıktı}) = 1/(1 + e^{-G_1(\text{girdi})}) = 1/(1 + e^{(-1.5125)}) = 0.81944$$

$$\zeta(\text{girdi}) = G_1 * w_{11} + G_2 * w_{12} + G_3 * w_{13} + b_1 = 0.8194403 * (0.5448) + 0.7905874 * (0.4382) + 0.7105095 * (0.0341) + (-0.57192) = 0.2458949$$

$$\zeta(\text{çıktı}) = 1/(1 + e^{-\zeta(\text{girdi})}) = 1/(1 + e^{(-0.2458949)}) = 0.5611658$$

Tablo 4.2 Gizli ve Çıktı Hücreleri İçin Girdi ve Çıktı Değerleri

Gizli1		Gizli2		Gizli3		Çıktı	
Girdi değeri	Çıktı değeri	Girdi değeri	Çıktı değeri	Girdi değeri	Çıktı değeri	Girdi değeri	Çıktı değeri
1.5125601	0.8194403	1.32847	0.7905874	0.89786	0.7105095	0.2458949	0.5611658
1.92413461	0.7757982	1.2855365	0.7833907	0.8928201	0.7094718	0.2189297	0.5545149
0.4668444	0.6146366	0.6260425	0.6515916	0.3009005	0.5746626	0.0687774	0.5171876
-0.1391301	0.4652735	1.2537615	0.7779503	1.0680598	0.7442278	0.048557	0.5121369
-0.4951095	0.3786906	0.993527	0.729784	0.84213	0.6989136	-0.021265	0.4946839
-0.1612334	0.4597787	1.1664392	0.7625008	0.977481	0.7266081	0.0381926	0.509547
-0.1348017	0.4663505	1.1135213	0.752785	0.9165479	0.7143382	0.0370971	0.5092732
-0.1886259	0.4529829	1.128324	0.7555295	0.9406362	0.7192282	0.0311838	0.5077953
-0.6870969	0.3346792	0.7526965	0.679766	0.6121953	0.6484414	-0.0688815	0.4827864
-1.1507679	0.2403488	0.2646273	0.5657734	0.1575226	0.5392994	-0.1739459	0.4566228
-1.4628611	0.1880301	0.0252466	0.5063113	-0.0526324	0.4868449	-0.2302942	0.4426796
1.9126609	0.1286822	-0.4227234	0.3958653	-0.466275	0.3854983	-0.3144803	0.4220215

Hatayı hesapla.

İlk örnek için hata değeri aşağıda hesaplanmış, diğer hücre değerleri de Tablo 4.3'de verilmiştir.

$$F_1 = (o_1^1 - y_1^1)^2 = (0.216479681 - 0.5611658)^2 = 0.118809$$

Durma ölçütlerinden biri tuttuysa, dur.

Durma ölçütlerine ulaşma henüz sözkonusu değil.

3. Geri-yayılma

n ← n+1

Her i çıktı birimi için aşağıdaki eşitliği hesapla.

$$\delta_i^\mu = (o_i^\mu - y_i^\mu) * f'(\sum_j w_{ij}^2 * v_j^\mu) \quad (4.19)$$

Tablo 4.3 12 ayrı veri için hata değerleri ve toplam hata

$(o_i^\mu - y_i^\mu)$	$(o_i^\mu - y_i^\mu)^2$
-0.34468615	0.118808542
-0.284892627	0.081163809
-0.275100204	0.075680122
0.387863138	0.150437814
-0.09419125	0.008871992
-0.409115818	0.167375753
-0.381813941	0.145781885
-0.370201271	0.137048981
-0.175048415	0.030641947
-0.071410563	0.005099469
-0.103838831	0.010782503
-0.141558409	0.020038783
Toplam Hata	0.4758658

Her j gizli birimi için aşağıdaki eşitliği hesapla.

$$\delta_j^\mu = f'(\sum_k w_{jk}^1 * x_k^\mu) * \sum_i w_{ij}^2 * \delta_i^\mu \quad (4.20)$$

Veri grubunun ilk ve son örnekleri için eşitliklerin hesaplanışının açık hali aşağıda gösterilmiştir. Diğer veriler Tablo 3.4'de sunulmuştur.

$$\delta_{çıkı}^1 = (-0.34468615) * (0.5611658) * (1 - 0.5611658) = -0.08488$$

...

$$\delta_{çıkıl}^{j2}=(-0.141558409)*(0.4220211)*(1-0.42202115)=-0.025618532$$

$$\delta_{gizli1}^j=(-0.08488)*0.5448*0.8194403*(1-0.8194403)=-0.006842$$

...

$$\delta_{gizli1}^{j2}=(-0.034528836)*0.5448*0.1286822*(1-0.1286822)=-0.002130878$$

4. Güncelleme

Öğrenme oranı ($\eta > 0$) olacak şekilde aşağıdaki formüllere göre gizli-çıkı ve girdi-gizli ağırlıklarını güncelleştir.

$$\Delta w_{ij}^2 = \eta \sum_{\mu} \delta_i^{\mu} * v_j^{\mu} \quad (4.21)$$

$$\Delta w_{jk}^1 = \eta \sum_{\mu} \delta_j^{\mu} * x_k^{\mu} \quad (4.22)$$

$$w_{ij}^2(\text{yeni})=w_{ij}^2(\text{eski})+\Delta w_{ij}^2 \quad (4.23)$$

Öğrenme oranı (η) 0.1 olarak hesaplamalara alınmıştır.

Tablo 4.4 Gizli Ve Çıkı Hücreleri İçin δ Değerleri

	$\delta_{çıkıl}$	δ_{gizli1}	δ_{gizli2}	δ_{gizli3}
	-0.084881977	-0.006842121	-0.006158012	-0.000595352
	-0.070376493	-0.006668874	-0.005233057	-0.000494658
	-0.068693783	-0.008864279	-0.006833669	-0.000572556
	0.096908651	0.01313529	0.007335622	0.000629037
	-0.023545151	-0.003018082	-0.002034601	-0.000168955
	-0.102241666	-0.013835204	-0.008113398	-0.000692577
	-0.095420652	-0.012937431	-0.00778145	-0.000663977
	-0.092527822	-0.012490854	-0.007488979	-0.000637158
	-0.043710236	-0.005302492	-0.004169485	-0.000339786
	-0.017718276	-0.001762442	-0.001907448	-0.000150115
	-0.025618532	-0.002130878	-0.002806063	-0.000218247
	-0.034528836	-0.002109182	-0.003618558	-0.000278921
Toplam	-0.56235	-0.06283	-0.04881	-0.00418

İlgili değerler kullanılarak ulaşılan yeni ağırlık değerleri Tablo 4.5'de verilirken her iki katmanın ilk ağırlık değerlerinin açık hesaplaması aşağıdadır.

$$\Delta w_{11(gizli-çıktı)} = 0.1 * (-0.0848 * 0.8194 + \dots + (-0.0345) * 0.12868) = -0.0291772$$

$$w_{11(gizli-çıktı)} = 0.5448 + (-0.0291772) = 0.5156228$$

Tablo 4.5 Güncellenmiş Ağırlık Değerleri

Çıktı-Gizli katmanı için		
w11	w12	w13
0.5156228	0.398713297	-0.002573216
Gizli-Girdi katmanı için		
w11	w12	w13
-26.72743748	9.82004753	14.61844462
w21	w22	w23
-60.35548653	-78.96253902	-75.78294598

$$\Delta w_{11(girdi-gizli)} = 0.1 * (-0.00684 * 0.09999 + \dots + (-0.002109) * 0.160955) = -0.00083748$$

$$w_{11(girdi-gizli)} = -26.7266 + (-0.00083748) = -26.72743748$$

$$\Delta w_{11(girdi-gizli)} = 0.1 * (-0.00684 * 0.09999 + \dots + (-0.002109) * 0.160955) = -0.00083748$$

$$w_{11(girdi-gizli)} = -26.7266 + (-0.00083748) = -26.72743748$$

Öğrenme oranının olabildiğince küçük bir değer olarak belirlenmesi etkin bir öğrenme sağlasa da sürecin çözüme ulaşma hızını azaltır (Leu ve diğ., 2001).

Formüle

$$\Delta w(n+1) = -\eta \frac{\partial E}{\partial w} + \alpha \Delta w(n) \quad (4.24)$$

olacak şekilde momentum değeri (α) eklemek ise hata gradyanı küçükken ağırlık güncelleme sürecini hızlandırmak için kullanılır (Tang ve Fishwick, 1993; Barnard, 1992). Momentum teriminin eklenmesi ile, bir önceki ağırlık değişiminin de mevcut durumda yapılan değişikliğe etki etmesi sağlanmış olur. Momentum sabiti olan α , Δw 'deki yüksek değişim sıklıklarını kontrol eder. Algoritmadaki öğrenme oranının küçük olması, sonucun bulunmasını çok yavaşlatır (Chiang ve diğ., 1996). Büyük olması ise ulaşılacak iyi noktaların atlanıp; daha kötü sonuçlara gelinmesine; yani eğer varsa, yerel minima noktasına saplanılmasına neden olabilir. Momentum sabiti, bunu engellemek için, yani, ağırlık değişimindeki yüksek değişim sıklıklarını

kontrol etmek için, formüle eklenebilir. Böylece her yeni atılan adım; bir önceki ağırlık değişimine de bağlanır.

Geri yayımlı öğrenme süreci boyunca ağırlıkların güncellenmesi iki farklı yolla yapılabilir (Battiti, 1992). Bunlardan ilki her bir örneğin ağırlık beslenmesinden sonra ağırlıkların güncellenmesidir ki sürekli geri yayılma (on-line BP) olarak adlandırılır. Diğeri ise tüm örnekler ağırlık beslenip çıktılar elde edildikten sonra ağırlıkların güncellenmesini gerektirir ve bu da toptan geri yayılma (batch BP) olarak adlandırılır. Sürekli geri yayılma yaklaşımı öğrenme başlamadan önce tüm örnekler elde hazır değilse ve girdi-çıkış çiftleri sürekli bir adaptasyonla belirleniyorsa kullanılmalıdır. Eğer öğrenme süreci boyunca kullanılacak veriler elde hazırsa ağırlıkların güncellenmesinde toptan geri yayılma yaklaşımını kullanmak daha uygundur.

5.Tekrar

2.adıma dön.

Aynı işlemler durma ölçütlerinden biri sağlanıncaya kadar tekrar edilmelidir.

Yukarıda basit bir örnek üzerinde adım adım incelenilen geri yayımlı öğrenme algoritması süreci boyunca üzerinde durulması gereken en önemli konu, sözkonusu sabitleri (öğrenme oranı ve momentum sabiti) öğrenme hızı ve doğruluğunu eniyeleyecek şekilde seçmek gerekliliğidir (Tang ve Fishwick, 1993).

4.2.1.2.2 Öğrenme Parametrelerinin Belirlenmesi

Gerçek hayatta karşılaşılan problemlerin çoğunluğunun tek gizli düzeye çözümlenebileceği belirtilmişti. Bu yüzden eğer üzerinde çalışılan yapay sinir ağı öğrenmesi beklenen fonksiyonu yeterince iyi öğrenemiyorsa, problem sinir ağının modelinde değil, çok büyük olasılıkla yetersiz eğitim ya da yetersiz sayıda gizli sinir hücresinin kullanılmasındadır. Zira yapay sinir ağının tasarımında, kullanılan gizli sinir hücresi sayısının da çok büyük rolü vardır. Bu konuda ise gerçekçi bir tahminde bulunmak oldukça zordur (Frean, 1990). Az kullanmak yetersiz öğrenmeye yol açtığı gibi, çok sayıda gizli sinir hücresi kullanmak da öğrenme aşamasında iyi sonuçlar verse de test aşamasında etkin bir öğrenmenin gerçekleşmemesine, yani sinir ağının eğitim verilerini sadece ezberlemesi, ancak öğrenmemesine neden olur (Masters,

1993; Curram ve Mingers, 1994). Zaten geri yayımlı öğrenme algoritmasının eleştirilen en önemli özelliği eğitim seti üzerinde doğru ağırlıklara ulaşana dek çok zaman geçmesi, bir diğer deyişle devir sayısının çokluğudur. Bir diğer eleştiri noktası ise yapay sinir ağının iyi bir performans sergilemesinin, gizli sinir hücresi sayısının doğru olarak belirlenmesine bağlı olmasıdır. (Alpaydın ve diğ., 1995). Tablo 4.6, gizli sinir hücresi sayısı ile öğrenme ve test aşamalarında yapay sinir ağının sergilediği performansı ortaya koyduğu için önemlidir (Gately, 1996). Söz konusu yapay sinir ağı bir adet gizli düzeye sahiptir. Tablo incelendiğinde sadece bir tane gizli sinir hücresinin kullanımının bile test aşamasındaki ortalama en az hata değerini %5'in altına düşürebildiği görülmektedir. Ayrıca en düşük hata yüzdesine de 3 gizli sinir hücresi ile ulaşmış, sinir hücresi sayısı büyüdükçe hata azalmamış, aksine dalgalanarak büyümüştür.

Tablo 4.6 Gizli Sinir Hücresi Sayısının Hata Üzerindeki Etkisi (Gately, 1996, s.73)

Gizli Düzeyde Bulunan Sinir Hücresi Sayısı	Ortalama En Az Hata
1	0.00446
2	0.00441
3	0.00425
4	0.00433
35	0.00440
7	0.00435
10	0.00430
15	0.00431
20	0.00426
30	0.00425
40	0.00426

Uygun gizli sinir hücresi sayısının bulunması için kullanılan kurallardan biri “geometrik piramid kuralı” olarak adlandırılır (Masters, 1993). Söz konusu kural, pratikte kullanılan birçok yapay sinir ağındaki sinir hücrelerinin piramid şeklini oluşturduğu yani girdilerden çıktılara doğru azalma gözlemlendiği varsayımına dayanır. Eğer kullanılan girdi sinir hücresi sayısının “n” ve çıktı sinir hücresi sayısının da “m” tane olduğu biliniyorsa, geometrik piramid kuralı uyarınca, gizli sinir hücresi sayısı;

$$\sqrt{m * n} \quad (4.25)$$


formülü ile bulunabilir. Ancak bu formülün ideal sayının bulunması için kabaca bir rakam ortaya koyduğu unutulmamalıdır. Gizli düzeyde kullanılması gereken sinir hücresinin sayısının belirlenmesi için önerilen diğer bir yol da girdi seviyesindeki hücrelerin %75'i kadar gizli sinir hücresi kullanmaktır (Salchenberger ve diğ., 1992). Gruca ve Klenz (1997) ise en etkin öğrenmeyi sağlayacak gizli sinir hücresi sayısının bulunması için “n” girdi hücresi sayısı ve “m” çıktı hücresi sayısı olmak üzere; $(2n+m)^{1/2}$ ile $(2n+1)$ arası bir değer önermektedirler. Hardgrave ve diğ. (1994) ile Venkatachalam ve Sohl'a (1999) göre ise uygun gizli sinir hücre sayısı girdi hücrelerinin yarısı ile iki katından bir fazlası arası bir değerdir.

Kullanılacak gizli sinir hücresi sayısının ideal değerini bulmak için en iyi yol biraz yorucu ve zaman alıcı olsa da çok küçük sayıda (örneğin iki) gizli sinir hücresi ile başlayıp arttırarak ve her seferinde belirlenen performans kriteri uyarınca yapay sinir ağının etkinliğini hesaplayarak ideal sayıyı belirlemektir (Masters, 1993). Bu süreç, denenen her gizli sinir hücresi sayısı için sözkonusu yapay sinir ağının eğitilmesini ve test edilmesini gerektireceğinden uzun fakat oldukça sağlıklı bir yoldur.

Yukarıda tanımlanan süreç boyunca dikkat edilmesi gereken en önemli şey, yapay sinir ağının veri grubunu ezberlemeyip öğrenmesini sağlamaktır. Bunun için de eğitim sürecindeki optimum iterasyon sayısını da belirlemek gerekir. Zira belirli bir noktadan sonra eğitim sürecindeki hata oranı azalmaya devam etse de genel veri grubunda performans düşme eğilimine girecek yani hata oranı yükselemeye başlayacaktır. Şekil 4.7, bir yapay sinir ağı için eğitim ve test verilerinin sinir ağının eğitilmesi için tekrarlanan iterasyon sayısı ile ilişkisini gösterdiği için önemlidir. Eğitim verisi, beklenen şekilde monoton şekilde azalıp bir yerde asimptota yaklaşmaktadır. Diğer veri grubu olan test veri grubunda ise hata başlangıçta azalsa da, eğitmeye devam etmekle hata beklenenin tersine artış göstermektedir.

Eğitim sürecinde kullanılan gizli sinir hücresi sayısı ve eğitim sürecinin uzunluğunun yanısıra dikkat edilmesi gereken bir üçüncü nokta da başlangıçta rassal olarak değer atanan ağırlıklardır. Rassal olarak atanmaları nedeniyle belirli sayıdaki gizli sinir hücresi ile sadece bir kez yapılan eğitim sürecinin etkinliği tartışmaya açıktır. Bu yüzden, ortalama bir deneme rakamı belirlenmeli ve herbir gizli sinir hücresi için yapay sinir ağı daha önceden belirlenen o rakam kadar tekrar tekrar çalıştırılmalıdır. Böylece rassallıktan kaynaklanan yanılgılarda büyük ölçüde ortadan kaldırılmış

olur. Ancak, tekrarlı öğrenme yapılsa bile sözkonusu gizli sinir hücresi sayısı için en iyi öğrenme etkinliğine ulaşıp ulaşılmadığının hiçbir zaman tam olarak bilinemeyeceği unutulmamalıdır.



Şekil 4.8 Eğitim İterasyon Sayısı (Masters, 1993, s.180)

Geri yayımlı öğrenme algoritmasında amaç, hata fonksiyonunu enküçükleyecek ağırlık değerlerini bulmaktır (Hagan ve diğ., 1996). Bu iteratif bir süreçtir ve rassal atanmış başlangıç ağırlık değerleriyle çalışmaya başlanır. Yapılan tahmin, aşağıdaki denklem uyarınca düzeltilerek devam edilir.

$$w_{k+1} = w_k + \alpha_k p_k \quad (4.26)$$

Burada p_k fonksiyonun enküçüklenmesi için gidilmesi gerekli yönü, α_k ise öğrenme oranını yani, sözkonusu yönde atılacak adımın uzunluğunu tanımlar. Süreç boyunca, her bir adımda ulaşılan hata değerinin bir öncekinden daha küçük olması istenir.

$$F(w_{k+1}) < F(w_k) \quad (4.27)$$

Bunun için de yeterince küçük bir öğrenme oranı için; fonksiyonun enküçüklenmesini sağlayacak “iniş”i gerçekleştirecek yönü belirlemek gerekir. w_k noktasında fonksiyon için Taylor serisinin birinci dereceden açılımı:

$$g_k \equiv \nabla f(w=w_k) \quad (4.28)$$

olmak üzere; aşağıdaki şekilde ifade edilebilir:

$$f(w_{k+1}) = f(w_k + \Delta w_k) = F(w_k) + g_k^T \Delta w_k \quad (4.29)$$

$F(w_{k+1})$ 'nin $F(w_k)$ 'dan küçük olması için yukarıdaki formülün sağ tarafının negatif olması gereklidir.

$$g_k^T \Delta w_k = +\alpha_k g_k^T p_k < 0 \quad (4.30)$$

Öğrenme oranı küçük, ama pozitif seçileceğinden:

$$g_k^T p_k < 0 \quad (4.31)$$

olarak yazılabilir. Bu denklemi sağlayan herhangi bir p_k vektörü “iniş yönü” olarak adlandırılır. Ve en dik iniş ise “ $-g_k$ ” en negatifken gerçekleşir. Bu ise, yön vektörü gradyanın ters işaretlisi iken gerçekleşir. Öyleyse; “en dik iniş” yöntemi

$$w_{k+1} = w_k - \alpha_k g_k \quad (4.32)$$

olarak ifade edilebilir.

Çok katmanlı ağlar için hata terimlerinin karesinin ortalaması çok karmaşık bir yüzey, belirler (Jacobs, 1988). Bunun yanısıra birçok yerel minima noktasına sahip olma olasılığı taşır. Bu yüzden de geri yayımlı öğrenme algoritması ile çalışırken, en iyi sonuca ulaştığımızı kesin bir şekilde bilmek mümkün değildir. Geometrik olarak bu, ağırlık uzayı üzerinde tanımlanan bir hata yüzeyi olarak ifade edilebilir.

Sözkonusu yöntem, hata fonksiyonunu en küçükmek için kullanılabilen iyi bir yöntemdir. Ancak, geri yayımlı öğrenme algoritmasının iki önemli dezavantajından bahsedilebilir (Hagan ve diğ., 1996). Bunlardan ilki öğrenmenin yavaş olması, ikincisi ise hata yüzeyinin yerel minimaya sahip olma olasılığıdır. Hata yüzeyi, süreci yavaşlatan özellikler taşır. Öyle ki, yüzey, ağırlık boyutunda oldukça düz ise; hataların türevi çok küçük olacaktır. Bu da; hatada meydana gelecek önemli bir azalmanın çok fazla sayıda adıma gereksinim duymasını zorunlu kılar. Zira, ağırlık değerlerinin her adımdaki değişimi oldukça küçük olacaktır. Bir diğer alternatif ise hata yüzeyinin çok eğimli olmasıdır. Bu durumda ağırlıkların türevi büyük olacaktır. Dolayısı ile ağırlık değerlerinin değişimi de büyük oranlarda meydana gelecektir. Bu da; hata yüzeyindeki en küçüklenecek noktanın atlanabilir olma olasılığını beraberinde getirir. Bu yüzden de yapay sinir ağının eğitimi başlangıç noktasının ve öğrenme parametrelerinin çeşitli defalar değişimini gerektirir. Böylece yerel minimuma saplanma riski de enazlanmış olur (Curry ve Morgan, 1996). Genellikle

öğrenme oranı eğitim süreci boyunca azaltılırken, momentum artırılır. Momentum terimi daha iyi değerlere sahip en küçük noktaların bulunabilmesini sağlamak üzere, ağırlıklarda meydana gelecek değişiklikler için yapılan hesaplamalara eklenebilir (Jacobs, 1988). Momentum sabiti, hem mevcut hem de geçmiş kısmi türevlerin mevcut durumdaki ağırlık değişimindeki göreceli etkilerini belirler.

Geri yayılmalı algoritmadaki öğrenme oranı gradyan iniş yöntemindeki adım büyüklüğüne (step size); momentum sabiti de düzleme çarpanına (smoothing term) benzer (Gruca ve Klenz, 1997). Yapılan araştırmalar yeterli küçüklükteki öğretilerinin algoritmanın en iyi çözüme ulaşmasını sağladığını ortaya koymaktadır. Ancak çok küçük değerlerdeki öğrenme oranları da aşırı uyan (over-fitted) bir yapay sinir ağına oluşmasına neden olur. İleri beslemeli ve üç düzeyli bir yapay sinir ağına eğitim sürecinde öğrenme oranı için 0.01 ile 0.5 arasında; momentum sabiti için de 0.7-0.9 arasında bir değer önerilmektedir. Öğrenme oranı ve momentum değeri için önerilen bir diğer değer çifti de aşağıdaki gibi bir eşitlikle ortaya konulabilir (Chiang ve diğ., 1996).

$$\eta=0.9 \quad \alpha=0.7 \quad (4.33)$$

Tüm bu parametrelerin belirlenmesini yanısıra eğitim sürecinin kesilmesi gereken nokta olan hata tolerans düzeyinin de belirlenmesi gereklidir (Hardgrave ve diğ., 1994). Zira, ağırlıkların belirlenmesi sürecinde çıktı hücrelerinin değerlerinin istenen değerlerinden sapma yüzdesi de eğitim sürecinin önemli bir parametresidir. Bu parametre belirlenirken yapay sinir ağına dahil hiçbir tekniğin %100 bir doğrulukla tahmin ya da sınıflama yapamayacağı dikkate alınmalı; incelenen problemin türüne göre uygun bir hata tolerans yüzdesi belirlenmelidir.

Söz konusu bu parametrelerin belirlenmesi süreci boyunca geçmiş verilerden yararlanılabilir (Curram ve Mingers, 1994). Diğer bir deyişle, geçmişte benzer problemlerde kullanılan parametre değerlerinden, mevcut durumda üzerinde çalışılan problem için yaklaşık değerler elde etmek üzere yararlanılabilir. Yine de, uygun bir yapay sinir ağı mimarisi ve parametre değerleri için belirli sayıda bir deneme-yanılma yapılması gerekliliği gözardı edilmemelidir.

4.2.2 Gözetimsiz Öğrenme

Bir diğer öğrenme türü ise gözetimsiz (unsupervised) öğrenmedir. Tıpkı gözetimli öğrenmede olduğu gibi yapay sinir ağına bir dizi girdi verilir ancak istenen çıktılar kıyaslama yapmak üzere elde değildir. Ağın öğrenme süreci, eğitim grubunun özelliklerini ağın keşfetmesi ve bu özellikleri kullanarak girdileri farklı özelliklerine göre gruplandırması üzerine kuruludur.

Bu tür öğrenmede gözetimli öğrenmede olduğu gibi ağın başarısının ölçüldüğü bir test veri grubunun var olmaması nedeniyle ağın hatasının tanımlanması ve ölçülmesi için kesin bir yol yoktur. Ancak yine de bu amaç doğrultusunda kullanılan bazı yöntemler vardır. Bunlardan en sık kullanılanı her bir ağırlık vektörünün, temsil ettiği sınıfın genel yapısına benzemesi gerekliliği fikrinden çıkar. Yani, eğitim sürecinde kullanılan veri grubuyla, içinde bulunduğu grubu temsil eden ağırlık vektörü arasındaki fark; bir çeşit hata göstergesidir. Her bir küme için bu şekilde bulunan hataların ortalaması, ağın performansı hakkında bir fikir verebilir. Diğer bir yöntem de ortalama hata yerine en büyük hataya bakmaktır. Çok büyük bir hata miktarı, öğrenmenin etkin bir şekilde gerçekleşmediğini ortaya koyabilir.

Yapay sinir ağlarının çoğunluğu gözetimli öğrenme yaklaşımını benimsese de bir kısım yapay sinir ağı uygulamaları gözetimsiz öğrenme başlığı altında toplanmalıdır. Gözetimsiz öğrenmeyi gözetimli öğrenmeden ayıran en belirgin fark, gözetimsiz öğrenmede ulaşılmak istenen çıktının elde veri olarak bulunmaması, yani önceden bilinmemesidir. Bu tarz yaklaşımda istenen, yapay sinir ağının eldeki verilerin yapısını keşfetmesidir.

Gözetimsiz öğrenme yaklaşımları içinde en bilineni yaratıcısının ismini (Teuvo Kohonen) taşıyan ve rekabetsel öğrenmeye dayalı olan Kohonen ağıdır. Gözetimli öğrenmede, sinir hücreleri, kendilerine ait bağlantıların ağırlıklarını eğitim sürecindeki hata oranını küçükleme hedefi doğrultusunda değişime uğratır. Kohonen ağlarında ise hücreler öğrenme ayrıcalığı için birbiri ile rekabet ederler. Gözetimli öğrenmeden en önemli farkı da buradadır. Gözetimli öğrenmede tüm ağırlıklar hatanın enküçüklenmesi için belirli oranlarda değişime uğrarken, bu tarz öğrenmede veri grubunun ağa beslendiği her bir seferde sadece bir (bazı durumlarda komşuları da olabilir) hücre ağırlıklarını değiştirme hakkına sahip olur. Kohonen ağları çok

basit bir temele otursa da sağladığı hız ve kolaylık açısından pratikte çok kullanılırlar.

Kohonen ağı iki düzeyli bir ağıdır. Ancak ilk düzey girdi normalizasyonu gerektirdiğinden bazen üç düzeyli olarak da tanımlanabilir. N adet girdisi olan ağda m çıktı olduğu varsayılırsa Kohonen ağı çok basit olarak ağırlıklı toplamdan oluşan ve çıktının aşağıdaki gibi hesaplandığı bir ağ olarak ortaya konulabilir.

$$\sum_{i=0}^{n-1} x_i w_i \quad (4.34)$$

Kohonen ağı, sınıflama problemleri için kullanılır. Çıktı hücrelerinin değerlerinin yukarıda verilen formül uyarınca belirlenmesinden sonra, en yüksek değerde uyarılmış olan hücre kazanan hücre olarak belirlenir ve ağıdaki bağlantıların ağırlıkları bu doğrultuda güncelleştirilir. Bir noktadan sonra sistem dengeye ulaşır yani, öyle ki belirli bir eğitim sürecinden sonra ağırlık vektöründe belirgin bir değişim gözlenmemeye başlanır. Bu aşamaya gelindiğinde eğitim tamamlanmış demektir ve artık en fazla uyarılan çıktının bulunması ile yapılan sınıflandırma işi, herhangi bir veri seti için gerçekleştirilebilir.

Eğitim sürecinde, ağırlıkların güncelleştirilmesi için iki farklı yöntem kullanılabilir. Toplamlı yöntem olarak adlandırılan ilk yöntemde; girdi vektörünün belirli bir oranı ağırlık vektörüne eklenir, ve toplam birim uzunluğa bölerek tekrar normalize edilir. Böylece ağırlık vektörü az bir şekilde veri grubunun doğrultusunda itilmiş olur. X^t 'in ağa verilen girdi vektörü ve w^t 'nin t zamanında kazanan hücre olarak belirlenen hücrenin ağırlık vektörü olduğu varsayılırsa; w^{t+1} yani güncelleştirilmiş ağırlık vektörü aşağıdaki gibi basit bir şekilde hesaplanabilir. Formüldeki η , öğrenme hızı olarak adlandırılır.

$$w^{t+1} = \frac{w^t + \eta x}{\|w^t + \eta x\|} \quad (4.35)$$

Yukarıdaki yöntemle alternatif olabilecek bir diğer ağırlık güncelleme yöntemi de çıkarımlı yöntemdir. Widrow-Hoff öğrenmesi olarak da adlandırılan bu yöntemde ağırlık vektörünün veri vektörü doğrultusunda yönlendirilmesinin bir yolunun da aralarındaki hata farkının bulunması olduğuna inanılır. Bu farkın belirli bir oranı

ağırlık vektörüne eklenirse, ağırlık vektörü veri vektörü doğrultusunda yönlendirilmiş olur. Yukarıdaki formülde kullanılan notasyonlar kullanılacak olursa yöntem aşağıdaki algoritmayı temel alır.

$$e_i = x - w^l \quad (4.36)$$

$$w^{l+1} = w^l + \eta e \quad (4.37)$$

Buradaki η , öğrenme oranı mutlaka 1'den küçük hatta en fazla 0.4 civarında olmalıdır. Genelde en iyi çözümlere yavaş öğrenme oranı ile ulaşılır.

Gözetimsiz öğrenmede üzerinde durulması gereken bir diğer yapay sinir ağı türü de temelinde Kohonen tipi öğrenme olan ve onun bir versiyonu sayılan özdüzenlemeli haritalardır (self-organization maps). Bu tür ağların en temel özellikleri bilginin tekil hücreler üzerinde değil belirli alanlarda odaklanmasıdır. Belirli bir hücre belirli bir yapıyı gösteriyorsa, komşuları da benzer yapıları sergilerler. Bu durum, her bir öğrenme adımında birden çok hücrenin öğrenmesini sağlamakla gerçekleşir. Kohonen ağındakine benzer şekilde veri grubunun ağa beslenmesinden sonra kazanan hücre belirlenir ve ağırlıkları güncellenir. Buna ek olarak, komşu hücrelerin de ağırlıkları güncellenir. Ancak komşu hücreler için kullanılan öğrenme oranı daha düşüktür; dolayısı ile ağırlıkları da daha az oranda değişime uğrar.

Özdüzenlemeli haritalar, bir girdi düzeyi ile çıktı düzeyinden oluşur (Maniameli ve diğ., 1996). Çıktı düzeyi, her bir çıktı hücresinin ağırlık vektörü ile girdiler arasındaki Öklid uzaklığını hesaplar. En yakın (enaz mesafede) olan çıktı hücresi 1 değerini alarak kazanan hücre ilan edilir. Diğer tüm hücreler sıfır değerini alırlar. Özdüzenlemeli haritalarda sinir ağı mimarisi tamamen kümeleme probleminin yapısına bağlıdır. Çıktı hücre sayısı, veri grubunun küme sayısına eşittir. Girdi hücre sayısı ise verilerin boyut sayısına eşittir.

Özdüzenlemeli haritalar türündeki yapay sinir ağlarında da tipik olarak girdi ve çıktı düzeyleri olmak üzere iki düzey vardır (Soylu ve diğ., 2000). Süreç sırasında ağırlık vektörü girdiye en çok yaklaşan çıktı hücresi kazanan olarak belirlenir ve sadece kazanan hücrenin bağlantıları değil, komşu hücrelerinin bağlantıları da belirli

oranlarda güncelleştirilir. Özdüzenlemeli haritalar için öğrenme algoritması aşağıdaki gibi özetlenebilir (Lippmann, 1987).

Adım 1. N adet girdiden m adet çıktıya olan bağlantıların başlangıç ağırlık değerlerini rassal ve küçük değerler olarak ata.

Adım 2. Yeni girdiyi ağı tanı.

Adım 3. Tüm hücreler için uzaklığı hesap et.

$$d_i = \sum_{j=0}^{n-1} (x_i(t) - w_{ij}(t))^2 \quad (4.38)$$

burada $x_i(t)$, t zamanında i.hücrenin girdi değeri, $w_{ij}(t)$ de t zamanındaki i girdi hücresinden j çıktı hücresine olan bağlantının ağırlık değeridir.

Adım 4. En küçük uzaklığa sahip çıktı hücresini (j^*)belirle.

Adım 5. j^* hücresinin ve komşu hücrelerinin ağırlık değerlerini güncelle.

$$w_{ij}(t+1) = w_{ij}(t) + \eta(t)(x_i(t) - w_{ij}(t)) \quad (4.39)$$

Burada η , yine öğrenme oranıdır.

Adım 6. Ağırlık değerleri sabitlenmediyse adım 2'ye dönerek tekrar et.

4.2.3 Karma (Reinforcement) Öğrenme

Gözetimli ve gözetimsiz öğrenme kadar sıklıkla kullanılsa da sözedilmesi gereken üçüncü bir tür öğrenme karma bir öğrenme türü olan karma öğrenmedir (Masters, 1993). Karma öğrenme, kesin çıktılar ağı karşılaştırma için verilemediği için gözetimsiz öğrenme olarak nitelendirilebilir. Ancak, ağı ürettiği çıktılar iyi ya da kötü olarak ayırt edilip, bu da yapay sinir ağına belirtilebildiği için gözetimli öğrenme olarak da nitelendirilebilir. Bazı kaynaklarda bu tür öğrenme doğru yanıtın ne olduğu belirtilmese de yanıtın doğru olup olmadığı belirtildiği, yani bir tür denetim uygulandığı için gözetimli öğrenme başlığı altında ele alınmaktadır.

4.3 Girdi Sinir Hücrelerinin Önem Sıralaması

Öğrenme ve test aşamaları tamamlanmış ve etkin bir şekilde çalıştığı düşünülen bir yapay sinir ağının ağırlık değerleri de üzerinde durulması gereken ayrı bir konudur (Masters, 1993). Zira ağırlık değerleri girdi hücrelerinin çıktı hücreleri üzerindeki etki ve/veya önemi konusunda bilgi verebilir. Bu konuda ilk akla gelen, girdi hücrelerini gizli hücrelere bağlayan ağırlıklardan değeri sıfıra yakın olanlara sahip girdi sinir hücrelerinin az öneme sahipken mutlak değerce büyük değerlere sahip olan girdi hücrelerinin öneminin de büyük olacağı doğrudur. Bazı yapay sinir ağı yazılım paketlerinde de bulunan bu girdi katkısı ölçüm tekniği eğitim sonrası çalıştırılır ve her bir girdinin tüm bağlantılarının ağırlıklarını toplayarak girdileri önem sırasına göre dizer (Gatley, 1996).

Ancak bu yaklaşım bazı durumlarda doğru olmayabilir (Masters, 1993). Eğer incelenen yapay sinir ağı tam bağlantılı değilse yani her bir girdi hücresi her bir gizli sinir hücresine; her bir gizli sinir hücresi de her bir çıktıya bağlı değilse bu ölçütün kullanılması çok da sağlıklı olmayan sonuçlar doğurabilir. Zira belki de sözkonusu büyük ağırlıklı girdinin bağlı olduğu gizli sinir hücresinin çıktı hücresiyle olan bağlantısını ağırlığı oldukça düşüktür ki bunun da sözkonusu girdi hücresinin çıktı üzerindeki etkisini düşereceği açıktır. Tersine de doğrudur. Yani ağırlık değeri düşük olan girdi-gizli çiftine ait gizli sinir hücresi ile çıktı hücresi arasındaki bağın kuvvetli olması sözkonusu girdinin de önemini arttıracaktır.

Benzer şekilde basit olduğu halde çok daha etkin bir ağırlık anlamlandırma yaklaşımı, duyarlılık analizi yapmaktır. Eğitim veri grubu ile elde edilen hata oranı, girdilerden biri sabit tutulup hata oranı üzerinde yarattığı etki incelenerek de girdinin önemi hakkında fikir sahibi olunabilir. Öyle ki, eğer hata oranında büyük bir değişiklik meydana gelmezse, sözkonusu girdinin önem sıralamasında gerilerde yer alması gerektiği sonucuna varılır. İncelenen girdi değerinin sıfıra eşitlenmesi halinde sözkonusu girdinin veri setinde hiç yer almamasının hata üzerinde yaratacağı etki yüzde olarak rahatlıkla incelenebilir.

Yoon ve diğ. (1993) tarafından ortaya konan ve gizli sinir hücrelerinin de girdi hücreleri üzerindeki etkilerini dikkate alan bir diğer ölçüm de aşağıda verilmiştir.

$$RS_{ji} = \frac{\sum_{k=0}^n (W_{ki} * U_{jk})}{\sum_{i=0}^m \left(\sum_{k=0}^n (W_{ki} * U_{jk}) \right)} \quad (4.40)$$

Çok katmanlı ağlarda tüm girdiler çıktılara gizli sinir hücreleri aracılığı ile bağlıdır, doğrudan bir bağ yoktur. Bu yüzden, her bir girdi değişkeninin karakteristiğinin belirlenebilmesi ve X_i girdisi ile O_j çıktısı arasındaki bağın kuvvetinin belirlenebilmesi için yukarıdaki formül kullanılabilir. Bu formülde RS_{ji} , i girdisi ile j çıktısı arasındaki bağın kuvvetidir. W_{ki} , k gizli birimi ile i girdi arasındaki ağırlık; U_{jk} j çıktı birimiyle, k gizli birimi arasındaki ağırlıktır. Bu istatistik; i girdisi ile j çıktısı arasındaki kuvvetin tüm girdi-çıkı değişkenlerinin toplam kuvvetine oranıdır. Paydadaki mutlak değer, girdi-çıkı değişkenleri arasındaki pozitif ilişkilerin negatif ilişkileri ortadan kaldırmaması için gereklidir.

Bu tez kapsamında yapılan çalışmada girdilerin önem sırasına gereksinim duyulduğunda, yukarıda anlatılan yaklaşımların üçü de kullanılmıştır. Problem için belirlenen yapay sinir ağı yapısı, tam bağlantılı olduğundan ilk tekniğin kullanılamamasının da bir sorun yaratmayacağına karar verilmiştir. Sonuç önem sırasının belirlenmesi için ise her üç yaklaşım için önemin belirlendiği ve 0-1 arası değişen değerlerin ortalamaları alınmıştır. Ancak son teknik olan gizli hücrelerin de etkisini dikkate alan formülde küçük bir değişiklik yapılmış ve onu daha etkin bir hale getirmeye yönelik olarak hem pay hem de payda değerlerinin karesi alınmıştır. Böylece ağırlık değerlerinin toplamı 1'e eşitlenmiş, formül aşağıdaki şekli almış ve bu şekliyle tez çalışmasında kullanılmıştır.

$$RS_{ji} = \frac{\left[\sum_{k=0}^n (W_{ki} * U_{jk}) \right]^2}{\sum_{i=0}^m \left[\sum_{k=0}^n (W_{ki} * U_{jk}) \right]^2} \quad (4.41)$$

4.4 YSA'nın Tahmin Modelleri İçin Kullanımı

Gelecek değerlerin tahmini oldukça genel bir problemdir (Masters, 1993). Ekonomistler, meteorologlar ve daha birçok meslek sahibi geleceğe yönelik bazı değerleri tahmin etmekten sorumludurlar. Yapay sinir ağları, bu konuda şu ana kadar uygulanan diğer tahmin yöntemlerine göre oldukça yeni olmasına rağmen etkin olarak kullanılabilirliğinin temelde iki nedeninden bahsedilebilir:

- i. Yapay sinir ağları öylesine çok yönlüdürler ki ilgilenen kişiyi birçok model arasından herhangi birini seçmek zorunda bırakmazlar. AR, MA, ARIMA ve daha birçok tahmin modeli arasından veri grubunu en iyi tahmin edeni bulmak zorunluluğu yerine yapay sinir ağına veri grubu beslenir, ve genellikle oldukça iyi sonuçlar veren kendi modelini bulması ve sonuçları ortaya koyması beklenir.
- ii. Yapay sinir ağları ile kaotik birçok bileşen diğer modellere göre daha iyi bir şekilde irdelenebilir.

Yapay sinir ağlarının ekonometrik modellere göre daha avantajlı bir konumda olmasının en temel nedeni eldeki veri grubu ile ilgili herhangi bir varsayıma gerek duymadan karmaşık ve doğrusal olmayan ilişkileri modelleyebilmeleridir (Alon ve diğ., 2001). Çok katmanlı yapay sinir ağları sadece girdi değişkenlerinde değil parametrelerde de doğrusal olmama özelliğine sahip parametrik regresyon modelleri olarak düşünülebilirler (Teixeira ve Rodrigues, 1996).

Yapay sinir ağları ile tahminde karşılaşılan en önemli tehlike fazlasıyla uyumdur (overfitting) (Masters, 1993). Birçok ağ, çok sayıda bağımsız parametreye sahip olduğundan eğitim veri grubunu oldukça iyi tahmin etse de genelde kötü performans sergileyen yapay sinir ağları ile karşılaşma mümkündür. Ancak bu tehlikenin de, diğer tüm yöntemlerde de gerekli olan, dikkatli bir test süreci ile rahatlıkla aşılabileceği unutulmamalıdır.

Bir yapay sinir ağının eğitilmesi ve kullanımı süreci bir dizi adımdan oluşur (Gately, 1996). Bu adımlar şöyle özetlenebilir:

- i. Üzerinde çalışılacak konunun belirlenmesi: Tahmini yapılacak konunun ve kapsamın belirlenmesi bir sonraki adımda gerekli olacak veri toplamanın etkinliği açısından önemlidir.

- ii. İlgili veri grubunun toplanması ve kullanıma hazır hale getirilmesi: Konunun kapsamı gözönünde bulundurularak konu ile ilgili değişkenler belirlenmeli ve bu değişkenlerle ilgili veriler toplanmalıdır. Daha sonra ise sözkonusu veri grubunun yapay sinir ağına kullanıma hazır hale getirilmesi gereklidir. Sinir ağına beslenecek verilerin normalize edilmesi gereklidir. Genellikle verileri [0 1] aralığı yerine [0.1 0.9] aralığına gelecek şekilde normalize etmek yapay sinir ağlarında sık ve etkin kullanılan bir yöntemdir (Tang ve Fishwick,1993).
- iii. Veri grubunun ikiye bölünmesi: Yapay sinir ağını eğittikten sonra sergileyeceği performansı görmek için test etmek şarttır (Gatelly, 1996). Bu yüzden de veri grubu eğitim ve test veri grubu olmak üzere ikiye bölünmelidir.
- iv. Uygun yapay sinir ağı mimarisinin seçilmesi: Yapay sinir ağlarında kullanılacak gizli düzey sayısı, gizli sinir hücresi sayısı, momentum sabiti ya da öğrenme hızı değerleri gibi belirlenmesi gereken parametreler vardır ki bunlar bütün olarak sözkonusu yapay sinir ağının mimarisinin temelini oluştururlar ve eğitim aşamasına geçmeden önce mutlaka belirlenmiş olmaları gereklidir.
- v. Uygun öğrenme (eğitme) algoritmasının seçilmesi: Literatürde incelenilen problemin tipine göre değişim gösteren algoritmalarından hangisinin kullanılacağı belirlenmelidir.
- vi. Yapay sinir ağının eğitilmesi: Eğitim veri grubu kullanılarak bu aşama tamamlanmalı ve benzer veri grupları sözkonusu ağa verildiğinde iyi tahminler gerçekleştirecek şekilde sinir hücreleri arasındaki bağlantıların ağırlıklarının belirlenmesi sağlanmalıdır. Yapay sinir ağları yardımı ile çözümlenen problemlerin %85'inde geri-yayılmalı öğrenme algoritması ve sadece bir gizli düzey kullanılmıştır.
- vii. Yapay sinir ağının test edilmesi: Eğitilmiş olan ağın, gerçekten etkin tahminler yapıp yapmadığı önceden ayrılmış olan test veri grubu ile ölçülmelidir.
- viii. Yapay sinir ağın kullanılması: Yeni veri grupları ya da mevcut verilerin ağa beslenmesi sonucu tahminlerin gerçekleştirilmesi.

Herhangi bir tahmin problemi için bir yapay sinir ağının eğitildiğini varsayalım (Masters, 1993). Sözkonusu ağın performansının mutlaka test verileri ile test

edilmesi şarttır. Test verileri içindeki bilinen noktalar kullanılarak yapay sinir ağı çalıştırılır ve tahminleri gerçekleştirmesi istenir. Daha sonra yapılan her bir tahmin için gerçekleşen tahmin değerleri ile eldeki asıl değerler karşılaştırılır. Bu aşamada bir tahmin tekniğinin etkinliğini ölçmek için üzerinde uzlaşma sağlanan tek bir performans ölçütü yoktur (Zhang ve Hu. 1998). Ancak yine de birçok yapay sinir ağının hataların karesinin ortalamasını (MSE) kullandığı söylenebilir (Masters, 1993). MSE, hedef değerler ile gerçekleşen değerler arasındaki farkın karesinin alınması, eldeki veri grubu için toplamın alınması ve daha sonra elde kaç veri varsa bu sayıya bölünerek ortalamanın bulunmasını gerektirir:

$$MSE = \frac{1}{n} \sum_{i=0}^{n-1} (t_i - o_i)^2 \quad (4.42)$$

Bu hata terimi en çok kullanılan olsa da benzer şekilde RMSE yani hataların karelerinin ortalamasının karekökü de çok kullanılan diğer bir performans ölçütüdür.

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=0}^{n-1} (t_i - o_i)^2} \quad (4.43)$$

RMSE, terimini kullanırken dikkat edilmesi gereken nokta, kullanılan veri grubunun ölçüm birimi büyüklüğüdür. Öyle ki, eğer tahmin edilen seri milyonlar düzeyindeyse 5 değerindeki bir RMSE küçük, ancak 10'lu sayılarla ifade edilmişse büyük olarak nitelendirilmelidir. Bu yüzden inch ile milimetre ölçüm birimlerini kullanan iki ayrı yapay sinir ağının performansı karşılaştırılırken sorun çıkabilir. Bu problemi ortadan kaldırmak için birimsiz bir değere sahip olmak yararlıdır. Hata terimlerinin karesinin toplamı ile hedeflenen değerlerin karesinin toplamının birbirlerine olan oranının bulunması ile de göreceli RMSE değeri elde edilir ve birimsiz olduğu için iki yapay sinir ağının performans karşılaştırmasında rahatlıkla kullanılabilir.

$$REL RMSE = \sqrt{\frac{\sum_{i=0}^{n-1} (t_i - o_i)^2}{\sum_{i=0}^{n-1} t_i^2}} \quad (4.44)$$

Bu performans ölçüm teriminde pay değerlerinden birinin 0 olması sonuçta yanıltıcı bir terime neden olabilir ki bu problem de aşağıdaki gibi küçük bir işlem eklemesiyle ortadan kaldırılabilir.

$$REL RMSE = \sqrt{\frac{\sum_{i=0}^{n-1} (t_i - o_i)^2}{\sum_{i=0}^{n-1} (t_i - \bar{t})^2}} \quad (4.45)$$

Daha az kullanılan birimsiz bir performans ölçüm terimi de herbir hata teriminin hedef değere bölünüp, toplamın alınmasından önce mutlak değerlerinin bulunması ile hesaplanabilir.

$$MRE = \frac{1}{n} \sum_{i=0}^{n-1} \left| \frac{t_i - o_i}{t_i} \right| \quad (4.46)$$

Yapay sinir ağları ile eğitim sürecinden sonraki test aşamasında, eğitim süreci sonunda elde edilen hata terimine yakın bir hata elde edilemiyorsa; bunun başlıca nedeni, eğitim sürecinde kullanılan örneklerin sayıca ya da nitelik açıdan yetersiz bilgi içeriyor olması olabilir. Bunun yanı sıra, yapay sinir ağının ağırlıklarının yeterince iyi belirlenememesi de diğer bir olası nedendir (Masters, 1993). Her iki durumda da eğitim süreci gerekli düzeltmeler yapılarak tekrarlanmalı ve bu aşama sonucu elde edilen değere yakın bir test değeri elde edilmesi sağlanmalıdır.

Yapay sinir ağları, tez çalışmasında, tahmin sürecinin yanısıra kümeleme analizi için de kullanılmıştır. Bu nedenle, bir sonraki bölümde yapay sinir ağları ile kümeleme analizi çalışması üzerinde durulacaktır.

4.5 YSA'nın Kümeleme Analizi İçin Kullanımı

Kümeleme analizi büyük ve karmaşık veri setini aynı grubun elemanları benzer özellikleri paylaşacak şekilde az sayıda veri gruplarına indirger (Chen ve diğ., 1995). Kümeleme analizi, her bir küme ya da grubun belirli özelliklere göre homojen olması yani grup içindeki elemanların birbirine benzeyecek şekilde ve her bir küme, bir diğerinden yine aynı özelliklere göre farklı olacak şekilde gruplandırılmasıdır (Özen, 2000). Kümeleme analizinde iki temel kavram vardır: uzaklık ve benzerlik. Uzaklık

iki elemanın birbirinden ne kadar ayırık olduğunu ortaya koyarken benzerlik de yakınlığın göstergesidir. Bu analiz tekniğinde elemanların birbirine olan yakınlıkları tüm değişkenlerin birbirine olan uzaklıklarının karesi olarak ifade edilebilecek Öklid uzaklığının karesine göre hesaplanır.

Kümeleme analizinde en sık kullanılan beş algoritma: basit bağlantı (single linkage), tam bağlantı (complete linkage), ortalama bağlantı (average linkage), merkezilik yöntemi (centroid method) ve Ward yöntemidir (Ward's method). Bu algoritmalar arasındaki temel farklılık kümeler arası uzaklığı hesaplamak için kullandıkları matematiksel süreçlerdedir. Herbirinin sistematik bazı eğilimleri (veya hataları) vardır. Merkezilik yöntemi; örneğin; düzensiz şekillerde kümeler yaratan bir hataya sahiptir: bunu yanı sıra sadece belirli aralıktaki ya da kesirli verileri kullanabilir. Basit bağlantı yönteminde en kısa uzaklığa sahip iki nesne aynı küme altında birleştirilir. Daha sonra en kısa uzaklığa sahip diğer ikili, ya 2. bir küme oluşturur; ya da bir önceki ikiliyle birleşerek yeni bir küme oluşturur. Tüm nesneler bir tek kümenin içine girinceye kadar bu süreç devam eder. Tam bağlantı yönteminde ise, benzer bir yöntem izlenir. Ancak, bu sefer, en uzun mesafeye göre kümeler oluşturulur. Ortalama bağlantıda; bir kümeden diğerine ortalama uzaklığa bakılır. Merkezilik yönteminde ise her küme, ortalaması ile temsil edilir ve bu ortalama değerler arasındaki Öklid uzaklığına bakılarak, en kısa uzaklığa sahip iki küme birleştirilir. Son olarak Ward yönteminde ise, her kümedeki tüm değişkenlerin ortalamadan sapmalarının kareleri alınır ve bu değer, en küçüklenecek şekilde kümeler oluşturulmaya çalışılır. Birçok alanda kullanılabilen kümeleme analiz çalışmaları için yapay sinir ağları oldukça yeni, bir o kadar da gürbüz (robust) ve kusursuz bir yaklaşım olarak karşımıza çıkar (Chen ve diğ., 1995). Gürbüz (Robust) olarak nitelendirilmelerinin en temel nedeni yapay sinir ağına girdi olarak sunulan veri eksik ya da yanlışlıklar barındırsa bile ağına anlamlı çözümler üretecek şekilde öğrenme yeteneğinin olmasıdır (Luk ve diğ., 2001). Kümeleme analizi için kullanılan yapay sinir ağları da gözetimsiz öğrenme kapsamındadır (Chen ve diğ., 1995). Zira önceden eğitim için ağına verilebilecek bir veri seti yoktur. Ancak ağdan elde edilen verileri en uygun şekilde gruplandırması beklenir. Özdüzenlemeli haritalar olarak da adlandırılan bu yapay sinir ağı türü özellikle veri grubu oldukça dağınıksa (high dispersion) yani gruplandırılması güçse, diğer kümeleme analiz tekniklerine

göre daha iyi sonuçlar verir. Veri grubunun dağınıklığı azaldıkça etkinliği diğer kümeleme analiz tekniklerine yaklaşır ancak hiçbir zaman onların aşağısına düşmez.

Yapay sinir ağlarının uygulamada birçok örneği ve kullanımı olsa da bu tez kapsamında, yapay sinir ağları yukarıda ayrıntıları açıklanan tahmin modelleri ile kümeleme çalışmaları için kullanılmıştır. Yapay sinir ağları için bilgisayar desteği, içerdikleri yoğun matematiksel işlem nedeni ile olmazsa olmaz koşuludur. Bu amaçla bazı bilgisayar paket programları araştırılmış ve içlerinden kullanım kolaylığı sağlaması nedeniyle MATLAB (1994) paket programı seçilmiştir. Tez kapsamında yapılan uygulama çalışmasına geçmeden önce 5.Bölümde sözkonusu paket programı hakkında özet bir tanıtıcı bilgi vermenin yararlı olacağı düşünülmüştür.



5 MATLAB YAZILIMI

5.1 Bilgisayar Desteğinin Gerekliliğı

Yapay sinir ağılarında tek bir hücrenin yapısı ve hareketi basit olsa da genel yapı ve hesaplamaları oldukça karmaşıktır. 3.Bölüm’de detayları anlatılan geri yayımlı öğrenme algoritmasının veya kümeleme analizi için kullanılan gözetimsiz öğrenme algoritmalarının etkin bilgisayar desteğı olmadan yapılamayacağı açıktır. Yapay sinir ağlarının mimarisindeki ve eğitim algoritmalarındaki hızlı gelişmeler, bilgisayar bilimindeki hızlı gelişmelerle paralel yürümektedir (Gately, 1996).


Bu tezdeki yapay sinir ağıları ile ilgili olan çalışmalarda MATLAB Paket Programı (1994) kullanılmıştır. MATLAB, sadece yapay sinir ağıları üzerine odaklanan bir program değil; optimizasyon, istatistik ve temel matematik ile ilgili birçok uygulamayı da içeren bir paket programdır. Yapay sinir ağıları ile ilgili olan kısmı, “Toolboxes” bölümü içindedir ve yapay sinir ağlarının tasarımı, eğitimi ve simülasyonu üzerine kuruludur.

Bu bölümde MATLAB’ın yapay sinir ağıları ile ilgili içerdiği ve bu tez kapsamında kullanılan temel fonksiyonlardan ve öğrenme kurallarından kısaca bahsedilmiştir.


5.2 Hareket Fonksiyonları

MATLAB paket programının kullanıma sunduğı birçok hareket fonksiyonu vardır. Sigmoid tipi olarak ise “logsig” (lojistik sigmoid) ve “tansig” (tanjant sigmoid) tipi hareket fonksiyonlarını kullanmak mümkündür. Türevi alınabilir olduğu için geri yayımlı öğrenme algoritmalarında sıkça kullanılan log-sigmoid fonksiyonu, verilen matrisi 0-1 aralığına dönüştürür. [-10, 10] aralığındaki değerlere uygulanan log-sigmoid fonksiyonunun çizimi Şekil 5.1’de verilmiştir. Bu fonksiyona alternatif olarak kullanılan diğer bir sigmoid tipi fonksiyon da tan-sigmoid fonksiyonudur. Bu

fonksiyon ise verileri $(-1, 1)$ aralığına dönüştürür. Yine $[-10, 10]$ aralığındaki değerlere uygulanan tan-sigmoid fonksiyonunun çizimi ise Şekil 5.2'de verilmiştir.



Şekil 5.1 Log-sigmoid tipi hareket fonksiyonu



Şekil 5.2 Tan-sigmoid tipi hareket fonksiyonu

5.3 Başlangıç Fonksiyonları

5.3.1 Initff Fonksiyonu

İleri beslemeli yapay sinir ağının ilk ağırlık ve hata terimlerinin rassal olarak atanmasını sağlar.

$[w1,b1,w2,b2]=initff(P,S1,F1,T,F2)$

gösterimi; “P” girdi matrisi, “T” çıktı matrisi, S1 gizli düzeydeki sinir hücresi sayısı ve “F” de kullanılan hareket fonksiyonu tipi olmak üzere ilk ağırlık değerlerinin rassal olarak atanmasını sağlar.

5.3.2 Inite Fonksiyonu

Rekabetisel öğrenme öncesinde ilk ağırlıkların rassal olarak atanmasını sağlar.

$w=initc(P,k)$

gösterimi “P” girdi matrisindeki verilerin k kümeye ayrılmasını sağlayacak şekilde ağırlık değerlerinin rassal olarak atanmasını sağlar. Bu formül aracılığıyla (girdi hücresi sayısı*küme sayısı (k)) kadar ağırlık değeri rassal olarak atanmış olur.

5.4 Eğitim Fonksiyonları

5.4.1 Trainbp Fonksiyonu

Geri yayımlı öğrenme algoritmasını kullanarak yapay sinir ağının eğitilmesi için kullanılır.

$[w,b]=trainbp(w,b,'F',P,T, tp)$

formülü ile tek düzeyli bir yapay sinir ağındaki “w” ağırlık matrisi, “b” hata matrisini, “F” hareket fonksiyonunu, “P” girdi ve “T” çıktı matrisleri ile “tp” öğrenme parametreleri dikkate alınarak ağı batch tipi eğitilmesi sağlanır. Formülün girdileri, yani eşitliğin sağ tarafındaki değerler, mevcut durumdaki girdi, çıktı ve ağırlık değerleridir. Formülün çıktısı ise, eşitliğin sol tarafındakiler, yani eğitim sonucu elde edilen yeni ağırlık değerleridir.

İstenirse değiştirilmesine izin verilen ancak standart olarak kullanılan ve “tp”yi oluşturan öğrenme parametreleri aşağıdaki gibidir.

Devirler arası gösterim sıklığı (df) =25

Öğrenme sürecinde kullanılan en fazla devir sayısı (me) =100

Ulaşılmak istenen hata hedefi(hataların karelerinin toplamı (sse) =0.02

Öğrenme oranı (lr)=0.01

Öğrenme, ya hata hedefi (sse) sağlandığında ya da ağ çalıştırılmak istenen en fazla devir sayısı (me) kadar çalıştırıldığında durur. Söz konusu fonksiyon kullanılarak yapılan öğrenme sonucunda yeni “w” ve “b” ağırlıkları ile ulaşılan hata terimi listelenir.

5.4.2 Trainbpx Fonksiyonu

İleri beslemeli bir yapay sinir ağının hızlı bir şekilde öğrenmesini sağlar. Bunun için yukarıda bahsedilen ve “trainbp” kodu ile yapılan öğrenmeye daha iyi çözümler vermesi amacıyla momentum eklenir ve süreç, değişen bir öğrenme oranı ile hızlandırılır. Öyle ki “trainbp” komutuyla 259.1sn ve 4123 devirde çözüme ulaşan bir yapay sinir ağı, “trainbpx” komutuyla 42.4sn’de ve sadece 570 devirde sonuca ulaşabilmektedir.

$[w,b]=\text{trainbp}(w,b,'F',P,T, tp)$

formülü ile tek düzeyli bir yapay sinir ağındaki “w” ağırlık matrisi, “b” hata matrisini, “F” hareket fonksiyonunu, “P” girdi ve “T” çıktı matrisleri ile “tp” öğrenme parametreleri dikkate alınarak ağı batch tipi eğitilmesi sağlanır. İstenirse değiştirilmesine izin verilen ancak standart olarak kullanılan ve “tp”yi oluşturan öğrenme parametreleri aşağıdaki gibidir.

Devirler arası gösterim sıklığı (df)=25

Öğrenme sürecinde kullanılan en fazla devir sayısı (me)=100

Ulaşılmak istenen hata hedefi(hataların karelerinin toplamı)(sse)=0.02

Öğrenme oranı (lr)=0.01

Öğrenme oranı artışı =1.05

Öğrenme oranı azalışı =0.7

Momentum sabiti =0.9

5.4.3 Trainc Fonksiyonu

Rekabetseel öğrenmede yapay sinir ağıının eğitilmesi için kullanılır.

$$w=trainc(w,P,tp)$$

formülü ile yapay sinir ağıındaki “w” ağırlık matrisi, “P” girdi matrisi ve “tp” öğrenme parametreleri dikkate alınarak ağıın batch tipi eğitilmesi sağlanır. İstenirse değıştirilmesine izin verilen ancak standart olarak kullanılan öğrenme parametreleri aşağıdadır.

Devirler arası gösterim sıklığı (df) =25

Öğrenme sürecinde kullanılan en fazla devir sayısı (me) =100

Öğrenme oranı (lr) =0,01

5.5 Simulasyon Fonksiyonları

5.5.1 Simuff Fonksiyonu

İleri beslemeli ağıın simülasyonunun yapılmasını sağlar.

$$simuff(P,w1,b1,F1)$$

formülü, “P” girdi vektörünü, “w1” ağırlıklarını “b1” hata terimlerini ve “F1” hareket fonksiyonunu kullanarak ağıın üreteceğı çıktıyı hesaplar. Böylece, test süreci için gerekli olan çıktı değerlerine ulaşılabilir. Bunun için, test aşaması için ayrılmış olan veri grubundaki girdi verileri ile, eğitim süreci sonucunda elde edilen ağırlıklar kullanılarak,ağıın çıktı değerlerini üretmesi istenir. Bu formül ile elde edilen çıktı değerleri daha sonra, test aşamasının hata teriminin bulunması için kullanılabilir.

5.5.2 Simuc Fonksiyonu

Rekabetseel öğrenmede, ağıın simülasyonunun yapılmasını sağlar.

$$a=simuc(P,w)$$

formülü, “P” girdi vektörünü ve “w” ağırlıklarını kullanarak ağıın üreteceğı çıktıyı hesaplar. Böylece gözetimsiz öğrenme ile verileri kümelendirmiş ve her bir küme

için ağırlık vektörleri (w) belirlemiş olan yapay sinir ağının, bu formüldeki P değeri ile tanımlanan girdileri hangi kümelere atayacağı tespit edilebilir.

5.6 Gözetimli Öğrenme için Bir Örnek

MATLAB paket programının çalışmasının daha iyi anlaşılması için aşağıda gözetimli öğrenme tipinde küçük bir örnek verilmiştir. İtalik yazılı satırlar sözkonusu satırı izleyen komutun açıklaması niteliğindedir.

- Başlangıç

Girdi ve çıktı değerlerinin tanımlanması

*Girdi vektörü olan "P" 21*1 boyutunda bir sütun vektörü olarak tanımlansın*

P = -1:1:1;

Çıktı vektörü olan "T", ilgili "P" değerine karşılık gelen hedef değerleri tanımlasın

T = [-.9602 -.5770 -.0729 .3771 .6405 .6600 .4609 .1336 -.2013 -.4344 -.5000 -.3930 -.1647 .0988 .3072 .3960 .3449 .1816 -.0312 -.2189 -.3201];

Yapay sinir ağının tasarımı

İki düzeyli bir yapay sinir ağı kullanılsın. Hareket fonksiyonları sırasıyla "tansig" ve "purelin" olsun. Gizli düzeydeki sinir hücresi sayısı da 5 olarak denensin

S1 = 5;

INITFF ağırlıkların başlangıç değerlerinin rassal olarak atanmasını sağlamak için kullanılsın.

[w1,b1,w2,b2] = initff(P,S1,'tansig',T,'purelin');

- Eğitim

Gösterim sıklığı 10 olsun.

df = 10

Öğrenme sürecinde kullanılan en fazla devir sayısı 8000 olsun

$me = 8000$

Ulaşılmak istenen hata hedefi 0,02 olsun

$eg = 0.02$

Öğrenme oranı 0,01 olsun

$lr = 0.01$

Sözkonusu 4 parametre "tp" (training parameters) ile adlandırılan bir değişken altında toplansın

$tp = [df \ me \ eg \ lr];$

Eğitim süreci başlasın

$[w1,b1,w2,b2,ep,tr] = \text{trainbpx}(w1,b1,'tansig',w2,b2,'purelin',P,T,tp);$

TRAINBPX: 0/8000 epochs, lr = 0.01, SSE = 25.8029.

TRAINBPX: 10/8000 epochs, lr = 0.0108593, SSE = 4.81122.

TRAINBPX: 20/8000 epochs, lr = 0.0176887, SSE = 3.44574.

...

TRAINBPX: 111/8000 epochs, lr = 0.0247639, SSE = 0.0198931.

Ulaşılan hata değeri hedef hata değerinden küçük olduğundan eğitim süreci burada bitiyor.

- Test

Eğitim sürecinin testi için 0.5 değerli girdinin, 0.3960 çıktı değerini sağlayıp sağlanmadığına bakıldığında çok yaklaşık bir değer olduğu görülmektedir.

$p = 0.5;$

$a = \text{simuff}(p,w1,b1,'tansig',w2,b2,'purelin')$

$$a = 0.3821$$

5.7 Gözetimsiz Öğrenme için Bir Örnek

MATLAB paket programındaki gözetimsiz öğrenme tipinin daha iyi anlaşılması için aşağıda küçük bir örnek verilmiştir. İtalik yazılı satırlar yine bir önceki örnekte olduğu gibi sözkonusu satırı izleyen komutun açıklaması niteliğindedir.

- Başlangıç

Kümelenecek vektörlerin tanımlanması

$$P = 0.1 / [(1/11):0.001:1] - 0.1;$$

Başlangıç ağırlık değerlerinin verilerin 6 kümeye bölünmesini sağlayacak şekilde belirlenmesi

$$w = \text{initc}(P,6);$$

- Ağın eğitilmesi

Gösterim sıklığı 50 olsun.

$$df = 50$$

Öğrenme sürecinde kullanılan en fazla devir sayısı 3000 olsun

$$me = 3000$$

Öğrenme oranı 0,02 olsun

$$lr = 0.02$$

Sözkonusu 3 parametre "tp" (training parameters) ile adlandırılan bir değişken altında toplansın

$$tp = [df \ me \ lr];$$

Eğitim süreci başlasın

$$w = \text{trainc}(w,P,tp);$$

TRAINC: 0/3000 epochs.

TRAINC: 50/3000 epochs.

...

TRAINC: 3000/3000 epochs.

Ulaşılan devir sayısı belirlenene eşit olduğundan eğitim süreci burada bitiyor.

- Uygulama

Artık yapay sinir ağı verileri kümelemeye hazırdır. 0.3 girdisinin hangi kümeye ait olduğuna bakıldığında 5.kümenin tepki verdiğini yani 0.3 girdisinin 5.kümeye ait olduğu ortaya konmuş olur.

$p = 0.3;$

$a = \text{simuc}(p,w)$

$a = (5,1) \quad 1$

MATLAB, oldukça kapsamlı bir paket program olması nedeniyle sadece yukarıda özetlenmeye çalışılan komutları değil daha birçok komutu bünyesinde barındırmaktadır. Ancak Bölüm 6'de anlatılacak olan uygulama kısmında yapay sinir ağları ile gerçekleştirilen tahmin çalışması ile kümeleme analizleri için sadece bu komutlar kullanıldığından sadece sözkonusu komutların açıklamalarının yeterli olacağı düşünülmüştür.

6 UYGULAMA

Tez kapsamındaki uygulama çalışmasında, yapay sinir ağıları ve bilişsel harita tekniklerinin kullanımı ile etkin ve öznel bilgidен uzak, yeni ve dinamik bir senaryo analiz yaklaşımı ortaya konmaya çalışılmıştır.

İncelenilecek konu olarak ise karmaşık yapısı, içerdіği belirsizlik, ülke gündemindeki önemi ve verilere ulaşabilme kolaylığı nedeniyle “Türkiye’de Enflasyon” konusu seçilmiş; konu ile ilgili etkin senaryolar ortaya koymak için bir süreç belirlenmeye çalışılmıştır.

6.1 Yöntem


Çalışmada, Türkiye’deki Enflasyon’la ilgili senaryolar üretme ana hedefi için EFAR yönteminden yararlanılmasına karar verilmiştir. Ancak yöntemin çok fazla öznel bilgiye dayalı olması, bir zayıf yön olarak görülmüştür. Bu nedenle, sözkonusu yöntemin izlediği adımlar temel alınmış olsa da kullanılan yaklaşımlar açısından oldukça büyük farklılıklar yaratılmıştır.

Akış şeması Şekil 6.1’de verilen uygulama sürecinin ilk adımında konu ile ilgili sektörlerin belirlenmesi için bilişsel harita yaklaşımından yararlanılmıştır. Bu amaçla, farklı uzmanların bireysel haritaları oluşturulmuş, daha sonra bu bireysel haritalar, ortak bir haritaya dönüştürülmüştür. Ortak bilişsel haritada varolan döngülerin incelemeyi kısıtlamaması için ise döngü analizi yapılmıştır. Sonuçta; farklı uzman yargıları kullanılarak, incelenilecek konu ile ilgili birçok değişken ortaya konmuştur. Bu değişkenlerin EFAR yaklaşımının da önerdiği üzere az sayıda olması ve konunun en belirgin özelliklerini yansıtmasını sağlamak amacıyla ise yapay sinir ağılarından yararlanılmıştır.

Sektörlerin belirlenmesinden sonra herbir sektör için toplanan veriler aracılığıyla yapılan çalışmalar sonucu olası durumlar belirlenmiştir.

Gelecekle ilgili olası durumların kümesi oldukça büyük olduğundan yine EFAR yaklaşımının önerdiği gibi kümeleme çalışması yapılmış ancak EFAR yaklaşımının bu aşamada bünyesinde barındırdığı öznellikten kurtulmak amacıyla yine yapay sinir ağlarından yararlanılmış, ve olası gelecek görüntülerini yansıtan durumlar gruplandırılmıştır.

Yöntem gereği, sözkonusu durumlar arası geçişlerin belirlenmesi için oluşturulan geçiş matrisinin yine öznel yargılar gerektirmesi nedeniyle de bu aşamada SPSS paket programı yardımıyla kümeleme analizi yapılmış ve gelecekle ilgili olası durumlar arası ilişkiler ortaya konmuştur.



Şekil 6.1 Uygulamada İzlenen Süreç

Son olarak ise belirlenen ilişkiler yardımıyla, temel senaryolar ile bu temel senaryoların içerdikleri farklı gelecek görüntüleri ortaya konmuştur. Ayrıca, gelecek görüntülerinin birbirleriyle olan ilişkileri de yönlü çizgeler aracılığı ile analize olanak tanıyacak şekilde belirlenmiştir.

6.1.1 Sektörlerin Belirlenmesi

Yapılan çalışmada enflasyonu etkilediği düşünülen tüm terimlerin tanımlanması, böylece girdi hücrelerinin nelerden oluşacağını ortaya konulabilmesi için öncelikle, detayları Bölüm 3’de anlatılan bilişsel haritalar yaklaşımından daha sonra da yine detayları 4. Bölümde anlatılan yapay sinir ağlarından yararlanılmıştır.

6.1.1.1 Bilişsel Haritalar Yaklaşımı


Enflasyon ile ilgili bilişsel haritalarını oluşturmak üzere, konu ile ilgili görüşlerine başvuru alan kişiler, Prof. Dr. Nurhan Yentürk, Doç. Dr. Lerzan Özkale ve Doç. Dr. Burç Ülengin, İTÜ İşletme Fakültesi İşletme Bölümü öğretim üyeleri olup, enflasyonla ilgili çalışmaları olan uzmanlardır.

Bu süreç dahilinde her bir uzmandan ilk önce enflasyon ile ilgili olduğunu düşündükleri (enflasyonu etkileyen ve enflasyondan etkilenen) tüm değişkenleri belirtmeleri istenmiş ve daha sonra ise bu değişkenlerden oluşan kare matristeki ikili karşılaştırmaları yapıp, 3 ilişki türünden (pozitif (+) / negatif (-) / ilişki yok (0)) birini seçmeleri sağlanmıştır. Her bir uzmanın oluşturduğu ikili karşılaştırma matrisi ve ilgili bilişsel haritası aşağıda verilmiştir. Bilişsel haritaların çizimi için Decision Explorer (1996) paket programından yararlanılmıştır.

Oluşturulan ilk ikili karşılaştırma matrisi olan ve Prof.Dr. Nurhan Yentürk’ün enflasyonla ilgili düşüncelerini yansıtan matris (Tablo 6.1) incelendiğinde 7 adet değişken tanımlandığı ve enflasyon dışındaki diğer 6 değişkenin hepsinin kendi aralarındaki ilişkilerinin yanısıra enflasyonu pozitif yönde etkilediği görülebilir. Bu matrisin bilişsel haritası Şekil 6.2’de verilmiştir. Bu haritada varolan tüm ilişkiler pozitif olduğundan şekil üzerindeki oklara herhangi bir işaret konmamıştır.

Tablo 6.1 Prof.Dr.Nurhan Yentürk'ün İkili Karşılaştırma Matrisi

	Net Dış Varlık Girişi	Devaluasyon	Faiz Oranı	Bütçe Açığı	Enflasyon Beklentisi	Para Arzı	Enflasyon
N. Dış Var.G.	0	0	0	+	0	+	+
Devaluasyon	0	0	0	0	+	0	+
Faiz Oranı	+	0	0	+	+	0	+
Bütçe Açığı	+	0	+	0	+	+	+
Enf. Bek.	0	0	0	0	0	0	+
Para Arzı	0	0	0	0	+	0	+
Enflasyon	0	0	0	0	0	0	0




Şekil 6.2 Prof.Dr.Nurhan Yentürk'ün Bilişsel Haritası

Oluşturulan ikinci ikili karşılaştırma matrisi olan ve Doç.Dr.Lerzan Özkale'nin enflasyonla ilgili düşüncelerini yansıtan matris (Tablo 6.2) incelendiğinde toplam 8 adet değişken tanımlandığı ve enflasyon dışındaki diğer 7 değişkenin hepsinin kendi aralarındaki ilişkilerin yanısıra enflasyonu pozitif yönde etkilediği görülebilir. Bu matrisin bilişsel haritası Şekil 6.3'de verilmiştir.

Oluşturulan üçüncü ikili karşılaştırma matrisi olan ve Doç.Dr.Burç Ülengin'in enflasyonla ilgili düşüncelerini yansıtan matris incelendiğinde toplam 20 adet değişken tanımlandığı görülebilir. Bu matrisin bilişsel haritası Şekil 6.3'de verilmiştir.

Tablo 6.2 Doç.Dr.Lerzan Özkale'nin İkili Karşılaştırma Matrisi

	Para Arzı	Faiz	Döviz Kurları	Kapasite Kullanım Oranı	Bütçe Açığı	Kamu Borçları	İstihdam	Enflasyon
Para Arzı	0	-	+	+	0	0	+	+
Faiz	-	0	-	-	0	0	-	+
Döviz Kurları	-	-	0	-	+	+	-	+
Kapasite Kullanım Oranı	0	0	0	0	-	-	+	+
Bütçe Açığı	+	+	0	-	0	+	-	+
Kamu Borçları	+	+	0	-	0	0	-	+
İstihdam	0	0	-	0	-	-	0	+
Enflasyon	+	+	+	+	+	+	+	0




Şekil 6.3 Doç.Dr.Lerzan Özkale'nin Bilişsel Haritası

Her üç uzmanın konu ile ilgili görüşlerini, temel teorik bilgileri doğrultusunda ve zaman boyutunu, bir diğer deyişle etki süresini dikkate almadan ortaya koymaları istenmiştir. Uzmanların bireysel bilişsel haritaları çıkarıldıktan sonra üzerinde çalışılan konu ile ilgili tüm görüşleri biraraya getirebilmek amacıyla toplu bilişsel

harita oluşturulmuştur. Toplu bilişsel haritanın oluşturulması için her bir uzmanın konu ile ilgili belirttiği kavramların toplu bir listesi oluşturulmuştur. Bunu yaparken sadece her üç uzmanın da belirttiği kavramların (kesişim kümesinin) toplu haritaya alınması yerine; veri tabanının olabildiğince büyük tutulabilmesi için tüm kavramlar (birleşim kümesi) alınmıştır.

Tüm kavramlardan oluşan ikili matris ise; her bir uzmanın haritasının çoğunluk kuralı uyarınca birleştirilmesi sonucu elde edilmiştir. Sözkonusu toplu bilişsel harita Şekil 6.5’de ve ikili karşılaştırma matrisi ise Tablo 6.4’de verilmiştir.





Şekil 6.4 Doç.Dr.Burç Ülengin'in Bilişsel Haritası

Tablo 6.3 Doç.Dr.Burç Ülengin'in İkili Karşılaştırma Matrisi

	Kamu Kesimi Açığı	Belirsizlik	Faiz	Döviz Kuru	Para Arzı	Sıcak Para Hareketleri	Ücretler	Kayıt Dışı Ekonominin Büyüklüğü	Kamu Harcama Planının Belirsizliği	Bankacılık Sistemindeki Aksaklıklar	Gelir Dağılımının Bozukluğu	Makro Plansızlık	Kapasite Kullanım Oranı	Kamu Borçları	Bütçe açığı	İstihdam	Net Dış Varlık Girişi	Devaluasyon	Enflasyon Beklentileri	Enflasyon
Kamu Kesimi Açığı	0	+	+	+	+	+	-	+	+	+	+	+	0	+	+	+	+	+	+	+
Belirsizlik	+	0	+	+	+	0	+	+	+	+	+	+	-	+	+	-	+	0	+	+
Faiz	+	0	0	-	-	+	0	+	+	+	+	+	-	+	+	-	+	-	+	+
Döviz Kuru	+	0	+	0	+	-	+	0	+	+	+	+	+	+	+	-	+	+	+	+
Para Arzı	0	0	-	+	0	0	+	0	0	+	0	0	+	0	0	+	0	+	+	+
Sıcak Para Hareketleri	+	+	+		0	0	0	+	+	+	+	+	+	+	+	+	+	0	0	0
Ücretler	+	0	+	0	0	0	0	0	0	0	-	0	-	+	+	-	0	0	+	+
Kayıt Dışı Ekonominin Büyüklüğü	+	+	0	0	0	+	0	0	+	+	+	+	0	+	+	0	0	0	0	0
Kamu Harcama Planının Belirsizliği	+	+	+	+	+	+	0	+	0	+	+	+	0	+	+	0	0	+	+	+
Bankacılık Sistemindeki Aksaklıklar	+	0	+	0	0	0	0	0	0	0	0	0	0	+	+	-	0	0	0	0
Gelir Dağılımının Bozukluğu	+	+	0	0	0	0	-	0	0	0	0	+	-	+	+	0	0	0	0	0
Makro Plansızlık	+	+	+	+	+	+	0	+	+	+	+	0	-	+	+	-	0	+	+	+
Kapasite Kullanım Oranı	-	0	+	0	+	0	+	0	0	0	0	0	0	0	0	+	0	0	+	+
Kamu Borçları	+	+	+	0	+	+	-	+	+	+	+	+	0	0	+	-	0	0	+	+
Bütçe açığı	+	+	+	0	+	+	-	+	+	+	+	+	0	+	0	+	0	+	+	+
İstihdam	+	0	+	0	0	0	+	0	0	0	-	0	+	0	0	0	0	0	+	+
Net Dış Varlık Girişi	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
Devaluasyon	+	+	+	+	+	+	+	0	+	+	+	+	+	+	+	+	0	0	+	+
Enflasyon Beklentileri	+	+	+	+	+	+	+	0	+	+	+	0	+	+	+	+	0	+	0	+
Enflasyon	+	+	+	+	+	+	+	0	+	+	+	0	+	+	+	+	0	+	+	0



Şekil 6.5 Toplu Bilişsel Harita

Tablo 6.4 Toplu İkili Karşılatırmalara Matrisi

	Kamu Kesimi Ağı	Belirsizlik	Faiz	Döviz Kuru	Para Arzı	Sıcak Para Hareketleri	Ücretler	Kayıt Dışı Ekonominin Büyüklüğü	Kamu Harcama Planının Belirsizliği	Bankacılık Sistemindeki Aksaklıklar	Gelir Dağılımının Bozukluğu	Makro Plansızlık	Kapasite Kullanım Oranı	Kamu Borçları	Bütçe açığı	İstihdam	Net Dış Varlık Girişi	Devalüasyon	Enflasyon Beklentileri	Enflasyon
Kamu Kesimi Ağı	0	+	+	+	+	+	-	+	+	+	+	+	0	+	+	+	+	+	+	+
Belirsizlik	+	0	+	+	+	0	+	+	+	+	+	+	-	+	+	-	+	0	+	+
Faiz	+	0	0	-	-	+	0	+	+	+	+	+	-	+	+	-	+	-	+	+
Döviz Kuru	+	0	0	0	0	-	+	0	+	+	+	+	0	+	+	-	+	+	+	+
Para Arzı	0	0	-	+	0	0	+	0	0	+	0	0	+	0	0	+	0	+	+	+
Sıcak Para Hareketleri	+	+	+	0	0	0	0	+	+	+	+	+	+	+	+	+	+	0	0	0
Ücretler	+	0	+	0	0	0	0	0	0	0	-	0	-	+	+	-	0	0	+	+
Kayıt Dışı Ekonominin Büyüklüğü	+	+	0	0	0	+	0	0	+	+	+	+	0	+	+	0	0	0	0	0
Kamu Harcama Planının Belirsizliği	+	+	+	+	+	+	0	+	0	+	+	+	0	+	+	0	0	+	+	+
Bankacılık Sistemindeki Aksaklıklar	+	0	+	0	0	0	0	0	0	0	0	0	0	+	+	-	0	0	0	0
Gelir Dağılımının Bozukluğu	+	+	0	0	0	0	-	0	0	0	0	+	-	+	+	0	0	0	0	0
Makro Plansızlık	+	+	+	+	+	+	0	+	+	+	+	0	-	+	+	-	0	+	+	+
Kapasite Kullanım Oranı	-	0	+	0	+	0	+	0	0	0	0	0	0	-	-	+	0	0	+	+
Kamu Borçları	+	+	+	0	+	+	-	+	+	+	+	+	-	0	+	-	0	0	+	+
Bütçe açığı	+	+	+	0	+	+	-	+	+	+	+	+	-	+	0	0	+	+	+	+
İstihdam	+	0	+	-	0	0	+	0	0	0	-	0	+	-	-	0	0	0	+	+
Net Dış Var. G.	0	0	0	0	+	0	0	0	0	0	0	0	0	0	+	0	0	0	0	+
Devalüasyon	+	+	+	+	+	+	+	0	+	+	+	+	+	+	+	+	0	0	+	+
Enflasyon Beklentileri	+	+	+	+	+	+	+	0	+	+	+	0	+	+	+	+	0	+	0	+
Enflasyon	+	+	+	+	+	+	+	0	+	+	+	0	+	+	+	+	0	+	+	0

Toplu harita üzerinde yapılan döngü analizi sonucu haritada birbiri ile yoğun ilişkide çok sayıda kavramın olması nedeni ile varolduğu düşünülen döngüler (loops) tespit edilmiştir. Döngülerin varlığı haritada dinamik bir yapı olduğunun en temel göstergesidir (Eden ve Ackermann, 1992). Bunun yanısıra, haritaların üzerinde yapılacak her analizi de etkileyeceğinden dikkat edilmesi gereken bir unsurdur. Bu yüzden, toplu bilişsel haritaya Wang'ın (1995) dinamik bilişsel harita yapıları için önerdiği yöntem uygulanmıştır. "Bilişsel haritalara yapay sinir ağı yaklaşımı" olarak adlandırılan sözkonusu yöntemin detayları Bölüm 3.4.1'de verilmiştir.

İncelenecek, bir başka deyişle sinir ağına beslenecek girdi değişkenin tespiti için; haritada merkezilik (domain) analizi yapılmış ve bunun sonucunda; 35 değeri ile "kamu kesimi açığı" ve "bütçe açığı" değişkenleri en merkezi değişkenler olarak belirlenmiştir. Sözkonusu değişkenler için gelen ve çıkan okların sayısı en yüksek olduğundan, bu değişkenlerin toplu haritanın en merkezi değişkenleri olduğu söylenebilir (Eden ve Ackermann, 1992).

Merkezilik analizi yapıldığında en yüksek değere iki değişken birden sahip olduğundan Wang'ın "Bilişsel haritalara yapay sinir ağı yaklaşımı" yönteminin her iki değişkene de uygulanması gerektiğine karar verilmiştir. Böylece, bu iki değişkenin, haritalar, döngüler açısından bir denge noktasına geldiğinde diğer değişkenlerden hangilerini etkileyeceğinin belirlenmesi istenmiştir.

Kamu kesimi açığı değişkenine yukarıda anlatılan yöntem gereğince 1, diğer değişkenlere 0 değeri atandığında elde edilen vektör:

$$X(1)=(1\ 0)$$

şeklindedir. Bu vektörün ağa beslenmesi ile başlayan sürecin detayları aşağıda verilmiştir.

		Değişkenler																			
		1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20
X1		1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
Y2		0	1	1	1	1	1	-1	1	1	1	1	1	0	1	1	1	1	1	1	1
x(1).W		0	1	1	1	1	1	-1	1	1	1	1	1	0	1	1	1	1	1	1	1
		0	1	1	1	1	1	-1	1	1	1	1	1	0	1	1	1	1	1	1	1

	x2																			
y(2)+x(1)	1	1	1	1	1	1	-1	1	1	1	1	1	0	1	1	1	1	1	1	1
	1	1	1	1	1	1	-1	1	1	1	1	1	0	1	1	1	1	1	1	1
	y3																			
x(2).W	14	11	10	6	9	9	3	8	12	14	13	11	1	12	13	1	6	7	11	12
	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1
	x3																			
y(3)+x(2)	2	2	2	2	2	2	0	2	2	2	2	2	1	2	2	2	2	2	2	2
	1	1	1	1	1	1	0	1	1	1	1	1	1	1	1	1	1	1	1	1
	y4																			
x(3).W	14	11	12	6	10	9	4	8	12	14	12	11	0	12	13	1	6	7	13	14
	1	1	1	1	1	1	1	1	1	1	1	1	0	1	1	1	1	1	1	1
	x4																			
y(4)+x(3)	2	2	2	2	2	2	1	2	2	2	2	2	1	2	2	2	2	2	2	2
	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1
	y5																			
x(4).W	15	11	13	6	10	9	4	8	12	14	11	11	-1	13	14	0	6	7	14	15
	1	1	1	1	1	1	1	1	1	1	1	1	-1	1	1	0	1	1	1	1
	x5																			
y(5)+x(4)	2	2	2	2	2	2	2	2	2	2	2	2	0	2	2	1	2	2	2	2
	1	1	1	1	1	1	1	1	1	1	1	1	0	1	1	1	1	1	1	1
	y6																			
x(5).W	16	11	12	6	9	9	3	8	12	14	11	11	-1	14	15	-1	6	7	13	14
	1	1	1	1	1	1	1	1	1	1	1	1	-1	1	1	-1	1	1	1	1
	x6																			
y(6)+x(5)	2	2	2	2	2	2	2	2	2	2	2	2	-1	2	2	0	2	2	2	2
	1	1	1	1	1	1	1	1	1	1	1	1	-1	1	1	0	1	1	1	1
	y7																			
x(6).W	16	11	10	7	8	9	1	8	12	14	12	11	-2	16	17	-2	6	7	11	12
	1	1	1	1	1	1	1	1	1	1	1	1	-1	1	1	-1	1	1	1	1

$$Y(6)=Y(7)=(1\ 1\ 1\ 1\ 1\ 1\ 1\ 1\ 1\ 1\ 1\ 1\ 1\ -1\ 1\ 1\ -1\ 1\ 1\ 1\ 1)$$

olması nedeniyle sistemin dengeye ulaşıldığı düşünülmüş ve analiz bu aşamada noktalanmıştır. Benzer şekilde bütçe açığı değişkenine yukarıda anlatılan yöntem gereğince 1, diğer değişkenlere 0 değeri atandığında elde edilen vektör:

$$X(1)=(0\ 0\ 0\ 0\ 0\ 0\ 0\ 0\ 0\ 0\ 0\ 0\ 0\ 1\ 0\ 0\ 0\ 0\ 0)$$

şeklindedir. Bu vektörün ağa beslenmesi ile başlayan sürecin ayrıntıları aşağıda verilmiştir.

Değişkenler

	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20
X1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	0	0	0	0	0
Y2																				
x(1).W	1	1	1	0	1	1	-1	1	1	1	1	1	-1	1	0	0	1	1	1	1
	1	1	1	0	1	1	-1	1	1	1	1	1	-1	1	0	0	1	1	1	1
x2																				
y(2)+x(1)	1	1	1	0	1	1	-1	1	1	1	1	1	-1	1	1	0	1	1	1	1
	1	1	1	0	1	1	-1	1	1	1	1	1	-1	1	1	0	1	1	1	1
y3																				
x(2).W	13	11	8	7	8	10	0	8	11	13	13	10	0	13	14	1	5	6	8	9
	1	1	1	1	1	1	0	1	1	1	1	1	0	1	1	1	1	1	1	1
x3																				
y(3)+x(2)	2	2	2	1	2	2	-1	2	2	2	2	2	-1	2	2	1	2	2	2	2
	1	1	1	1	1	1	-1	1	1	1	1	1	-1	1	1	1	1	1	1	1
y4																				
x(3).W	15	11	9	6	8	9	2	8	12	14	13	11	1	13	14	0	6	7	10	11
	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	0	1	1	1	1
x4																				
y(4)+x(3)	2	2	2	2	2	2	0	2	2	2	2	2	0	2	2	1	2	2	2	2
	1	1	1	1	1	1	0	1	1	1	1	1	0	1	1	1	1	1	1	1
y5																				
x(4).W	15	11	11	6	9	9	3	8	12	14	12	11	0	13	14	0	6	7	12	13
	1	1	1	1	1	1	1	1	1	1	1	1	0	1	1	0	1	1	1	1
x5																				
y(5)+x(4)	2	2	2	2	2	2	1	2	2	2	2	2	0	2	2	1	2	2	2	2
	1	1	1	1	1	1	1	1	1	1	1	1	0	1	1	1	1	1	1	1
y6																				
x(5).W	16	11	12	6	9	9	3	8	12	14	11	11	-1	14	15	-1	6	7	13	14
	1	1	1	1	1	1	1	1	1	1	1	1	-1	1	1	-1	1	1	1	1
x6																				
y(6)+x(5)	2	2	2	2	2	2	2	2	2	2	2	2	-1	2	2	0	2	2	2	2
	1	1	1	1	1	1	1	1	1	1	1	1	-1	1	1	0	1	1	1	1
y7																				
x(6).W	16	11	10	7	8	9	1	8	12	14	12	11	-2	16	17	-2	6	7	11	12
	1	1	1	1	1	1	1	1	1	1	1	1	-1	1	1	-1	1	1	1	1

$$Y(6)=Y(7)=(1\ 1)$$

olması nedeniyle sistemin dengeye ulaşıldığı düşünülmüş ve analiz bu aşamada noktalanmıştır.

Bu noktada iki farklı değişkenle yapılan incelemenin aynı iterasyon sayısında ve aynı çıktılarla dengeye oturmasının sadece bir rastlantı olduğu belirtilmelidir. Diğer bir değişkenle yapılacak analiz tamamen farklı sonuçlar doğurabilir.

Bu çıktılar uyarınca, uzmanların toplu haritasına göre, hem kamu kesimi açığında hem de bütçe açığında meydana gelen bir değişikliğin kapasite kullanım oranı (13.değişken) ve istihdam (16.değişken) üzerinde negatif bir etki yaratacağı diğer tüm değişkenler üzerinde ise pozitif bir etki yapacağı söylenebilir. Önemli olan ise tüm değişkenlerin kamu kesimi açığı ve bütçe açığında meydana gelen bir değişimden etkileneceği gerçeğidir. Bu sonuç, toplu haritanın yoğun ve çok etkileşimli yapısı düşünüldüğünde doğal olarak gözüксе de, önemli olan bu sonuca, sözkonusu haritadaki dinamik yapının bir dengeye oturtulmasından sonra erişildiği gerçeğidir.

Buna göre toplu bilişsel haritada yer alan tüm değişkenlerin (20 değişken) bu tezin uygulama kısmında incelenmesi gerektiğine karar verilmiştir. Sözkonusu değişkenler aşağıda listelenmiştir.

- | | |
|---------------------------------------|-------------------------------|
| • Kamu Kesimi Açığı | • Gelir Dağılımının Bozukluğu |
| • Belirsizlik | • Makro Plansızlık |
| • Faiz | • Kapasite Kullanım Oranı |
| • Döviz Kuru | • Kamu Borçları |
| • Para Arzı | • Bütçe açığı |
| • Sıcak Para Hareketleri | • İstihdam |
| • Ücretler | • Net Dış Varlık Girişi |
| • Kayıt Dışı Ekonominin Büyüklüğü | • Devaluasyon |
| • Kamu Harcama Planının Belirsizliği | • Enflasyon Beklentileri |
| • Bankacılık Sistemindeki Aksaklıklar | • Enflasyon |

Bu değişkenlerden “Faiz, Döviz Kuru, Para Arzı, Sıcak Para Hareketleri, Ücretler,

Kapasite Kullanım Oranı, Kamu Borçları, Bütçe açığı, İstihdam, Net Dış Varlık Girişi, Devaluasyon ve Enflasyon Beklentileri'nin aylık verilerine ulaşılabildiği için bu 12 değişkenin yapay sinir ağına verilecek girdi değişkenleri olmalarına; "enflasyon" değişkeninin ise ağına çıktı değişkeni olmasına karar verilmiştir. Geri kalan 7 değişken yöntemin gerektirdiği nicel ölçülebilirliği sağlayamadıkları için bu aşamada elenmişlerdir.

6.1.1.2 Yapay Sinir Ağları Yaklaşımı

Yapay sinir ağına kullanılacak olan sözkonusu 13 değişken belirlendikten sonra her bir terimin geçmiş verilerinin sinir ağına eğitime/test etme süreçlerinde kullanılmak üzere toplanması ve gerekli veri hazırlama işlemlerinin yapılması aşamasına geçilmiştir.

Yukarıda sözü edilen ve sinir ağına girdi ve çıktıları oluşturacak toplam 13 değişkenin aylık verileri Devlet Planlama Teşkilatı, Hazine Müsteşarlığı ve Merkez Bankasının kaynaklarından bulunmuştur. Ortak veri tabanı Ocak 1994-Aralık 1998 dönemini kapsamış ve bu dönemin ilk 4 yılının ağına eğitim sürecinde; son 1 yılının ise test sürecinde kullanılması uygun bulunmuştur. Sözkonusu veriler ek-A'da verilmiştir.

Sinir ağına beslenecek verilerin normalize edilmesi gerekmektedir. Ancak verileri [0 1] aralığı yerine [0.1 0.9] aralığına gelecek şekilde normalize etmek yapay sinir ağlarında daha sık kullanılan ve daha etkin olduğu belirtilen bir yöntem olduğundan (Tang ve Fishwick,1993) bu çalışmada da aynı şey uygulanmış, tüm veriler [0.1 0.9] aralığına normalize edilmişlerdir.

Bu çalışmada en çok kullanılan sinir ağları paradigmalarından biri olan ileri-beslemeli sinir ağı ve buna bağlı olarak da geri-yayılmalı öğrenme algoritması kullanılmıştır. Yukarıda sözü edilen 12 değişken girdi hücresi, enflasyon değişkeni de çıktı hücresi olarak belirlenmiştir. Gizli sinir hücresi katmanı olarak sadece bir tane kullanılması uygun bulunmuştur; zira birden fazla gizli katmanın yer almasının pratikte bir yarar sağlamadığı ve öğrenmeyi yavaşlattığı ortaya konmuştur (Masters, 1993).

Gizli katmanda yer alan sinir hücresi sayısının belirlenmesi için Masters (1993)'ın önerisi dikkate alınmış ve 2 gibi oldukça küçük bir değerden başlayarak yapay sinir ağı test edilmiştir. Böylece en az hatayı veren gizli sinir hücresi sayısının sözkonusu yapay sinir ağı için uygun olduğuna karar verilmiştir. Bunun yanısıra, ağı eğitilmesi sürecindeki "en iyi nokta" yakalanmaya çalışılmıştır. Amaç, ezberlemenin başladığı yerde eğitim sürecini durdurmaktır. Bu noktayı belirlemek için izlenen yol, belirli aralıklarla eğitime sürecini durdurmak, test verileri için sonuçları gözlemlemek, eğer test verileri için bulunan hata terimi azalmaya devam ediyorsa eğitmeye devam etmek ama eğer durduysa, eğitim sürecini o noktada kesmektir.

Bu çalışmada kullanılan MATLAB paket programı bazı diğer paket programların aksine bu yöntemi otomatik olarak gerçekleştirmediği için kullanıcının belirli aralıklarla yukarıda bahsedilen testi yapması gerekmektedir. Bu çalışmada her 1000 epoch'ta bir bu test yapılmış, hata terimlerinin karesi 0.01'in altına düştüğünde bu aralık her 100 epoch'ta bir indirilmiştir. Ayrıca Tang ve Fishwick (1993)'in de önerdiği üzere, her bir gizli sinir hücresi sayısı için rassal ağırlıkların atanması, dolayısıyla ağı çalıştırılması 10'ar kez tekrarlanmıştır.

Yapay sinir ağı eğitilmesinde öğrenme oranının küçüklüğü daha yavaş öğrenmeye yol açar. Ancak büyük öğrenme oranları da algoritmanın dengeden uzaklaşmasına, büyük sıçramalar yapmasına, dolayısı ile en iyi noktayı yakalayamamasına neden olduğundan yapılan çalışmada öğrenme oranı 0.01 olarak alınmıştır.

Momentum sabitinin öğrenme sürecine katılması ile yerel minimumdan kaçıp, global minimuma erişmek daha kolaylaşacağından bu çalışmada da momentumlu geri yayımlı algoritma kullanılmıştır ve momentum sabiti 0.9 olarak alınmıştır.

Bu çalışmanın sonucunda en iyi değerler 4 gizli sinir hücresi için bulunmuştur (Matlab paket programının sözkonusu en iyi değerleri veren işleyişinin ayrıntıları Ek-B'de verilmiştir). Tablo 6.5'de test verileri olan Aralık-Ocak 1998 aylarının enflasyon değerlerinin normalize edilmiş rakamları ile sinir ağı tahmin ettiği değerler verilmiş, ilgili grafik ise şekil 6.6'da çizilmiştir. Buna göre; hata terimlerinin karesi, 0.0054; hata terimlerinin karesinin ortalaması ise 0.000447 olarak bulunmuştur. 4 gizli sinir hücresi sayısı için farklı rassal ağırlık değerleriyle yapılan

10 deneme sonucu ulaşılan MSE değerleri; hata yüzeyinin değişikliğini yansıtmak amacıyla; Tablo 6.6'da verilmiştir.

Tablo 6.5 Çıktı Verilerinin Karşılaştırılması (Normalize edilmiş değerler)

	Gerçek	Tahmin
Ocak	0.2939	0.2725
Şubat	0.2269	0.2269
Mart	0.202	0.2151
Nisan	0.2476	0.2857
Mayıs	0.1761	0.2096
Haziran	0.1111	0.0951
Temmuz	0.1773	0.1573
Ağustos	0.1965	0.2081
Eylül	0.3052	0.2703
Ekim	0.2835	0.2842
Kasım	0.2187	0.2234
Aralık	0.177	0.1658

Elde edilen sonuç enflasyonun iyi bir şekilde tahmin edildiği yargısını doğursa da sonuç diğer tahmin modellerinin aynı verilerle elde ettiği başarı ile karşılaştırılmıştır. Böylece yapay sinir ağının gerçekten etkin bir tahmin yapıp yapmadığının ortaya konması istenmiştir.

Tablo 6.6 Farklı Rassal Başlangıç Ağırlıklarına Ait MSE Değerleri

Deneme No	MSE
1	0.00240
2	0.00330
3	0.00838
4	0.01900
5	0.00045
6	0.00347
7	0.00630
8	0.00970
9	0.02300
10	0.00810


Yapay sinir ağının başarısının kıyaslandığı ilk tahmin. bir zaman serisi modeli olan AR (Autoregressive) modeli ile yapılmıştır. Söz konusu modelde, geçmiş seri değerlerinin doğrusal bileşimi ile e_t gibi bir hata teriminin toplamından oluşan bir y_t seri değeri elde edilir. Tez kapsamındaki karşılaştırma çalışması için kullanılan için AR modeli, aşağıdaki gibi ifade edilebilir:

$$ENF_t = (1 - 0.413L)(1 - 0.2468L^{12})enf_t \quad (6.1)$$

Karşılaştırma yapılan diğer tahmin ise çoklu regresyondur. Çoklu regresyonun, ölçülebilir bir bağımlı değişkenin, bir ya da daha çok ölçülebilir bağımsız değişkenle ilişkili olduğu durumlarda tahmin için kullanılması uygundur. Tez kapsamındaki karşılaştırma çalışması için kullanılan için çoklu regresyon yapısı aşağıdaki gibi ifade edilebilir:

$$ENF_t = 0.924 + 0.2802ENF_{t-1} + 0.2248ENF_{t-12} + 0.2063DEVAL_{t-1} + 10.01UCART \quad (6.2)$$

Yapılan çalışma sonucu elde edilen değerler Tablo 6.7’de verilmiştir. Tablo incelendiğinde MSE, RMSE VE RELMSE değerlerinin üçünde de en iyi sonuçlara, diğer bir deyişle en küçük hata değerlerine yapay sinir ağları yardımı ile ulaşıldığı görülmüştür.



Şekil 6.6 Çıktı Verilerinin Karşılaştırılması

Çalışmada yapay sinir ağlarının kullanımının temel nedeni EFAR yaklaşımı sürecinin başındaki sektörlerin etkin bir şekilde belirlemesini sağlamaktır. Bu amaçla çıkan sonuçlar uyarınca her bir girdinin göreceli önemini belirlenmesi ve en önemli değişkenlerin sektör tanımları olarak çalışma kapsamına alınması gerekmektedir.

Tablo 6.7 Sonuçların Karşılaştırılması

	Gerçek değer	Ar Model	Regression	Yapay Sinir Ağı
Oca.98	6.742042464	4.516	5.774	6.0965625
Şub.98	4.724327136	5.78792	5.610157	4.7228625
Mar.98	3.974028024	4.556522	5.539068	4.3673875
Nis.98	5.345943544	5.137401	5.201656	6.4942125
May.98	3.192429557	5.08394	4.612007	4.2017
Haz.98	1.235166298	3.58546	4.633804	0.7523875
Tem.98	3.227553803	3.892132	4.484898	2.6261625
Ağu.98	3.805660537	5.196563	4.207391	4.1565125
Eyl.98	7.080663025	5.389446	3.66351	6.0302875
Eki.98	6.429283714	6.897286	3.659623	6.449025
Kas.98	4.475809332	5.384672	4.871398	4.617425
Ara.98	3.219328053	4.3551	4.955872	2.882225
mse		1.928541715	3.501686706	0.405311877
rmse		1.388719451	1.87127943	0.63664109
relmse		0.084415998	0.113749339	0.03869946

Bu amaçla yapay sinir ağı ile yapılan çalışmadaki en iyi ağırlık değerlerine gereksinim vardır.

$w1 =$ -1.293 -0.3075 0.2289 -0.967 0.621 1.4656 0.8831 2.1474 0.9793 -0.669 -1.158 0.6591
0.5731 -0.5516 -0.175 1.7362 -1.599 -0.648 -0.979 -1.619 0.192 1.5752 -0.318 -1.081
0.9344 -0.3593 0.0497 -1.363 -1.8645 -0.374 0.7431 -1.490 -0.550 0.9796 -0.728 -0.784
-0.4354 1.059 -0.934 0.4795 0.8988 0.3146 0.6315 0.8839 -0.962 -1.056 0.2753 -1.060

$b1 =$ -0.107

-0.051

1.6699

-1.583

$w2 =$ -1.2534 -1.0198 -0.2498 -0.3818

$b2 =$ 0.0332

Sözkonusu bu ağırlıklar yardımıyla Bölüm 4.7’de anlatılan üç yöntemden de yararlanılmış ve sonuçlar Tablo 6.8’de verilmiştir. İlk sütundaki ölçüm Yoon ve diğ.(1993) tarafından ortaya konan ölçümün hem pay hem de payda değerlerinin karesi alınmış halidir.

$$\frac{\sum_{k=0}^n (W_{ki} * U_{jk})^2}{\sum_{i=0}^m \left(\sum_{k=0}^n (W_{ki} * U_{jk}) \right)^2} \quad (6.3)$$

2.ölçüm, Gately (1996) tarafından önerilen göreceli katkı dikkate alınarak hesaplanmıştır. 3.ölçüm için ise Masters (1993) tarafından önerilen duyarlılık analizi yaklaşımı kullanılmıştır. Her bir ölçüm kendi içinde bir sıralama ortaya koyduğundan bu üç sıralamanın ortalamaları alınarak birleştirilmiş ve son bir ortak önem sıralamasına ulaşılmıştır.


Elde edilen bu önem sıralaması dikkate alınarak hangi değişkenlerin sektör tanımlamaları olarak belirleneceğine karar vermek için sonuç değerlerinin Şekil 6.7'de verilmiş olan grafiği çizilmiş ve en büyük kırılmanın olduğu noktaya kadar olan ilk 4 değer çalışmaya alınacak sektörler olarak ortaya konmuştur.

Tablo 6.8 Girdi Değişkenlerinin Önem Sıralaması

	1.Ölçüm	2.Ölçüm	3.Ölçüm	Sonuç
Faiz	0.0880423	0.043975952	0.027457384	0.053158542
Döviz Kuru	0.037613	0.03173276	0.008916997	0.026087597
Para Arzı	0.0052256	0.165452301	0.027959799	0.066212578
Sıcak Para Hareketleri	0.0150475	0.022853958	0.020893194	0.019598219
Ücretler	0.0891778	0.387024208	0.132749212	0.202983738
Kapasite Kullanım Oranı	0.1354902	-0.150780379	0.019093617	0.00126781
Kamu Borçları	0.0268494	-0.254538939	0.000903736	-0.075595277
Bütçe Açığı	0.0946591	0.015766842	0.352185283	0.154203749
İstihdam	0.0790551	0.068024367	0.053175104	0.06675152
Net Dış Varlık Girişi	0.0347427	-0.165074056	0.006466491	-0.041288286
Devaluasyon	0.3218734	0.384097786	0.118812822	0.274928005
Enflasyon Beklentisi	0.0722239	0.451465201	0.23138636	0.251691804

Grafikten de görülebileceği gibi en yüksek öneme sahip ilk dört değer; devaluasyon, enflasyon beklentisi, ücretler ve bütçe açığı'dır. Daha sonraki değişkenlerin önem

değerleri ile ilk dört değişkenin arasında ciddi bir fark olduğundan EFAR sürecine girecek değişkenler olarak bu dört değişken belirlenmiştir.



Şekil 6.7 Değişkenlerin Önem Sıralaması

6.1.2 Gelecekle İlgili Tüm Durumların Ortaya Konması

EFAR yaklaşımında sektörlerin belirlenmesinden sonra her bir sektör için ilgili seviyelerin belirlenmesini, daha sonra ise sektör-seviye çiftlerinin birleştirilmesi ile gelecekle ilgili tüm durumların ortaya konması izler.

Tez kapsamında yapılan çalışmada belirlenen dört sektör için düzey belirlenmemiş; bunun yerine eldeki veriler kullanılarak, 100 adet senaryo, diğer bir deyişle gelecek görüntüsü ortaya konmuştur. Zira, öznel bilgiden uzak ve tamamen sayısal ilerleyen süreçte, her bir değişken için düzey belirleyip, daha sonra da değişken-düzye bileşimlerinin üzerinden ilerlemek, yöntemin en büyük eksikliği olarak nitelendirilen öznel bilgiye gereksinim duyulması yanışını beraberinde getirecekti. Oysa önerilen yöntemde eldeki sayısal geçmiş veriler kullanılarak ve Excel Add-In programlarından “SIM.XLA” yardımıyla her bir dört değişkenin, geçmiş verilerinin ortalamasından ± 3 standart sapma içinde bulunacak şekilde 100 adet rassal değer alması sağlanmıştır. Sözkonusu gelecek görüntüleri Ek C’de verilmiştir.

6.1.3 Anlamsız Bileşimlerin Elenmesi

Oluşturulan 100 adet gelecek görüntüsünün içinden anlamsız durumların elenmesi için EFAR yaklaşımında kullanılan yöntemden daha farklı bir yöntem izlenmiştir. Yaklaşımın orijinalinde, bu aşamada öznel bilgiye dayalı olarak anlamsız bileşimlerin reddi vardır. Söz konusu bu öznelikten kurtulmak için önce yapay sinir ağları ile kümeleme analizi yapılmış daha sonra ise korelasyon analizi ile anlamsız durumlar elenmiştir.

6.1.3.1 Kümeleme ve Korelasyon Analizleri

Bu aşamada toplam 100 adet gelecek ile ilgili durumdan eleme yapılmasını sağlama için eldeki veriler yapay sinir ağına beslenmiş ve 10 adet gruba ayırması istenmiştir. MATLAB sonuçları Ek-D'de verilmiştir. Söz konusu kümeleme analizinde programa verileri 10 adet gruba bölmek istendiği bilgisinin yanısıra öğrenme oranının 0.1 olması istendiği de belirtilmiştir. Toplam epoch sayısı 10000 olarak belirlenmiştir.

Daha sonraysa yapay sinir ağları ile elde edilen 10 adet kümeye kendi içlerinde korelasyon çalışması yapılmış ve aralarındaki korelasyonun düşük olduğu diğer bir deyişle anlamsız olduğu kümelerin atılması yoluyla eleme gerçekleştirilmiştir. Yapılan çalışmalar sonucu elde edilen kümeler ile korelasyon analizi sonuçları Ek E'de verilmiştir. Korelasyon sonuçları “kötü” çıkanlar (3, 4, 7 ve 9 kümeleri) çalışmanın bundan sonraki adımlarına alınmamışlar böylece anlamsız bileşimlerin elenmesi sağlanmıştır.

6.1.4 Olurlu Bileşimlerin Kümelenmesi

Bir önceki adımda yapılan eleme sonucu ortaya çıkan ve 1, 2, 5, 6, 8 ve 10 numaralı kümelerde yer alan 54 adet olurlu bileşimin inceleme kolaylığı sağlanması amacıyla kümelenmesi gerekmektedir. EFAR sürecinin orijinalinde bu çalışma değerleri birbirine yakın olan durumların birleştirilmesi ve sonuç değerleri için de ortalama alınması ile gerçekleştirilmektedir.


Bu çalışmada ise izlenen sürecin orijinalinden farklılığı nedeniyle bu adımda da yapay sinir ağlarından yararlanılmış ve kümeleme analizi gerçekleştirilmiştir. Bu amaçla yapay sinir ağına toplam küme sayısının tüm olurlu durumların yarı sayısı olan 27 adet olması istendiği bildirilmiştir. Bunun yanısıra öğrenme oranı yine 0.1 olarak

belirlenmiştir. MATLAB'ın ilgili çıktısı Ek-F'de verilmiştir. Birleştirilmiş durumlar ve ilgili değerleri Tablo 6.9'de verilmiştir.

6.1.5 Durumlar Arası Geçişin Belirlenmesi

Kümeleme çalışması sonucu 27 adete indirgenen olurlu durumlar arası geçişlerin ortaya konması için tekrar bir kümeleme analizi yapılmıştır. Ancak bu seferki çalışmanın asıl amacı kümelemek değildir. SPSS paket programı ile yapılan bu çalışma sonucu çıkan dendrogramdan yararlanılmak istenmiştir.

Dendrogram kümeleme analizinin görsel bir sunuş şeklidir (Özen, 2000). Birleştirilmesi ve kümelenmesi uygun olan durumları ortaya koyan dendrogram, gerçek uzaklıklar yerine 0-25 aralığındaki sayılara göre yeniden ölçeklendirilmiş bir uzaklık ölçümü kullanır. Dendrogram soldan sağa doğru okunur. Yatay çizgiler birleştirilmiş kümeleri, çizginin konumu ise kümenin hangi mesafede birleştirildiğini gösterir. Çalışmada Ward's minimum varyans yöntemi kullanılmıştır. SPSS yardımı ile ortaya konan dendrogram Şekil 6.8'de verilmiştir. Bu dendrogram yardımı ile 27 adet durum arasındaki ilişkiler bir geçiş matrisine gereksinim duymaksızın rahatlıkla belirlenebilir.



Şekil 6.8 Senaryoların SPSS Yardımıyla Kümeleniş Gösterimi

6.1.6 Gelecek Görüntülerinin Çizgelere Aktarılması


Gelecek görüntülerinin çizgelere aktarılması için gerekli olan son çalışma yine yapay sinir ağları yardımı ile aralarındaki ilişkilerin belirlenmiş olduğu eldeki 27 adet gelecek görüntüsünü içerecek şekilde temel senaryoları ortaya koymak için kümeleme analizi yapmaktır.

10000 epoch süren ve öğrenme oran 0.1 olarak belirlenmiş olan kümeleme analizinin MATLAB çıktısı Ek-G'de, sonuçları ise Tablo 6.9'da verimiştir.

Tablo 6.9 Senaryoların Oluşturulması için Yapılan Kümeleme Analiz Sonuçları

Birleştirilmiş Durumlar	Küme No'su	Ücretler	Bütçe Dengesi	Devaluasyon	Enflasyon Beklentisi	Ait Olduğu Senaryo
42-99	1	580.795	-4891950.465	6.333483912	4.5916803	4
31	2	668.84	-6165418.338	2.316328908	2.8639206	3
94	3	651.736	-2227602.236	3.478555052	6.2031281	1
1-27-84	4	682.405	-5628963.288	2.342068941	6.3464887	3
25-86	5	597.223	-2716009.106	7.372586639	4.4475277	4
32-100	6	557.945	-3478999.782	4.71392399	4.5044737	4
76	7	673.066	-3467899.205	4.054697472	7.2153241	2
85-91	8	655.009	-3610419.549	3.057377386	6.7166697	2
40-49	9	643.176	-1755678.049	1.535248979	5.1716766	1
19-28	10	618.579	-4105812.538	6.938147568	3.2910189	4
4-41	11	697.476	-3469388.881	2.640689089	6.9423477	2
90-6-17-29-87	12	668.511	-4777576.853	5.915884997	4.7962583	4
68-34-63	13	642.075	-4108924.769	2.347516729	6.7311260	2
59	14	638.589	-1478063.559	2.130584691	0.1527946	1
74	15	661.647	-4964264.227	2.917677233	6.8163313	2
8-14-43	16	639.835	-6250968.367	1.724434768	8.5862211	3
79	17	667.044	-1390240.349	0.465158085	6.6425032	1
44-81	18	585.702	-1385767.48	3.605967748	4.7016275	1
11-24-71-98	19	642.164	-5026874.735	1.62526842	1.5547718	3
26	20	672.649	-3526077.009	2.995975138	5.8029344	2
23-96	21	600.531	-1713901.655	2.582331695	6.3331426	1
52-89	22	694.897	-3669829.643	1.709689497	5.6559148	2
10-22-60	23	712.764	-4965050.774	0.142269181	5.7759849	3
35	24	682.259	-4646905.244	3.678966216	5.9547582	2
3-12	25	682.909	-2594998.488	5.39000341	5.1003744	2
45	26	647.021	-4483211.917	3.331343946	5.9129704	2
13-92	27	650.692	-3373166.093	5.216231155	4.0769490	4


10 durum gözönüne alınarak “Türkiye’de Enflasyon” konusuyla ilgili oluşturulan 27 adet gelecekle ilgili olası durumun 4 ana senaryo altında toplanmış ve birbiri ile ilişkilendirilmiş hali Şekil 6.9 ve Şekil 6.10’da verilmiştir.



Şekil 6.9 Senaryo İçi İlişkiler

Bunun için, yararlanılan dendrogramdaki ilişkiler incelenmiştir. Örneğin, 26 ile 15 arasındaki kümelemenin varlığı, çizgeye ikili ilişki olarak yansıtılmıştır. Benzer şekilde 27 ve 25’in oluşturduğu küme ile sözkonusu bu kümenin 12 no’lu senaryoyla oluşturduğu ikinci küme de çizgeye, üçünün de birbirleriyle ilişkili olması şeklinde

yansıtılmıştır. Bu ilişkilerin varlığı 4 ana kümeye varıncaya kadar sürdürülmüştür. Olası bir karışıklığı engellemek amacıyla Şekil 6.9'da sadece senaryo içi ilişkilere Şekil 6.10'da da sadece senaryolar arası ilişkilere yer verilmiştir.



Şekil 6.10 Senaryolar Arası İlişkiler

Çalışma sonucu ortaya konan dört temel senaryo ve içerdikleri gelecek görüntüleri, diğer bir deyişle ayrıntı senaryolar ile sözkonusu senaryoların içerdikleri gelecek görüntülerinin bileşen değerlerinin ortalamaları alınarak elde edilmiş temel senaryo değerler Tablo 6.10'da verilmiştir.

Tablo 6.10 Temel Senaryolar ve Bileşenlerin Ortalama Değerleri

Temel Senaryo	İçerdikleri Senaryolar	Ortalama Değerler			
		Ücretler	Bütçe Açığı	Devaluasyon	Enflasyon Beklentisi
1	3-9-14-17-18-21	631.13	-1658542.22	2.29964	4.867479
2	7-8-11-13-15-20-22-24-25-26	670.90	-3854191.89	3.21239	6.284875
3	2-4-16-19-23	669.20	-5607455.1	1.63007	5.025478
4	1-5-6-10-12-27	612.29	-3890585.81	6.081708	4.28465

Bu aşamaya gelinmesi için kullanılan veri tipi aylık olduğundan, elde edilen senaryoların kısa dönemli olduğu söylenebilir. Bu bir dezavantaj gibi gözükse de; birbirleriyle ilişkide olan senaryoların bağlantıları sayesinde bir sonraki kısa dönemin de incelenmesi ve bu şekilde uzun vadeye bakılabilmesi olanaklıdır. Öyle ki; sözgelimi, mevcut durumda içinde bulunulan durum 25 no'lu senaryo ise; kısa dönemde bu senaryodan geçiş yapılabilecek olan senaryoların 1, 5, 6, 10, 12 veya 27 olduğu söylenebilir. En olası senaryo olarak 6 no'lu senaryonun seçildiğini varsayalım. Bu defa; ikinci kısa dönem öngörüsü olarak bu senaryodan hangi senaryolara geçiş yapılabileceği incelenebilir ve bu olasılık zinciri devam ettirilerek uzun dönemli hareketler üzerinde durulabilir.

Tablo incelendiğinde 1 no'lu senaryonun içerdiği değerler dolayısıyla temel olarak alınabilecek bir senaryo olduğu görülmektedir. Buna rağmen 2 no'lu senaryoda tüm değerlerin oldukça kötü olması nedeniyle, bir bütün olarak "kötü" bir geleceği yansıttığı söylenebilir. 3 no'lu senaryoda ise dövizdeki artışın frenlenmiş olduğu, buna rağmen ücret ve bütçe açığının düşürülemediği olduğu ortaya çıkmaktadır. 4 no'lu temel senaryoda ise ücretlerin baskı altında tutulduğu, devaluasyonun çok yüksek, enflasyon beklentisinin ise en düşük değerde olduğu görülmektedir. Diğer bir deyişle, enflasyon beklentisi yüksek devaluasyonla kırılmaktadır.

Bu genel açıklamadan sonra senaryoların veriler uyarınca kontrol amaçlı yorumlamasına geçilmelidir. İncelenmek üzere Ocak 2000'in verileri ve bu verilerin

kontrolü için de Şubat 2000'in verileri elde edilmiştir. Buna göre ilgili değerler, aşağıdaki gibi belirlenmiştir.

Tablo 6.11 İlk Örnek İçin Veriler

Dönem	Ücretler	Bütçe Dengesi	Devaluasyon	Enflasyon Beklentisi
Oca.00	1,300	-1590867	3.430878	5.531
Şub.00	1.263	-2862978	3.404732	4.513

Gelecek görüntüleri içinden, Ocak 2000'in verilerine en yakın değerler 17 no'lu ayrıntı senaryoya aittir. Sözkonusu bu senaryoyu bulmak için Ocak 2000'in verileri ile tüm ayrıntı senaryolar arasında excel yardımıyla korelasyon analizi yapılmış ve en yüksek değeri veren, diğer bir deyişle, 3 sözkonusu veriler ile en kuvvetli ilişkisi olan gelecek görüntüsü kontrol amaçlı ayrıntı senaryo olarak seçilmiştir. 17 no'lu senaryoya ait veriler de aşağıda verilmiştir.

Tablo 6.12 İlk Örnek İçin Kontrol Verileri

Ayrıntı Senaryo	Ücretler	Bütçe Dengesi	Devaluasyon	Enflasyon Beklentisi
17	667.044	-1390240.349	0.465158085	6.64250329

Şekil 6.8 ve 6.9 incelendiğinde 17 no'lu senaryonun 3 / 9 / 18 ve 21 no'lu senaryolarla ilişkili olduğu görülür. Sözkonusu bu ayrıntı senaryoların Tablo 6.9'da verilen değerlerine bakıldığında ise bu durumdan geçilecek olan olası durumda ücretlerin düşmesi, devaluasyonun ve enflasyon beklentisinin azalması her 4 senaryo için de geçerli olduğundan mutlak gibi gözükmemektedir. Bütçe açığı ise dört senaryonun üçü için yükselme eğilimde olduğundan büyük olasılıkla yükselecektir denilebilir. Gerçekten de Şubat verileri incelendiğinde ücretlerin ve enflasyon beklentisinin azalmış olduğu ve yine beklendiği üzere, bütçe açığının da yükseldiği görülmektedir. Sadece devaluasyon beklenen artışı göstermemiş: hemen hemen sabit bir değerde kalmıştır.

Benzer şekilde incelenmek üzere Ağustos 2000'in verileri ve bu verilerin kontrolü için de Eylül 2000'in verileri elde edilmiştir. Buna göre ilgili değerler, aşağıdaki gibi belirlenmiştir. Gelecek görüntüleri içinden, Ağustos 2000'in verilerine en yakın değerler 10 no'lu ayrıntı senaryoya aittir.

Tablo 6.13 İkinci Örnek İçin Veriler

Dönem	Ücretler	Bütçe		Enflasyon Beklentisi
		Dengesi	Devaluasyon	
Ağu.00	1,554	-10316688	2.852791	4.559
Eyl.00	1,542	-10034253	2.919756	6.96

Bir önceki örnekte olduğu gibi yine korelasyon analizi yapılmış ve en yüksek korelasyonu sözkonusu ayrıntı senaryo elde etmiştir. 10 no'lu senaryoya ait veriler de aşağıda verilmiştir.

Tablo 6.14 İkinci Örnek İçin Kontrol Verileri

Ayrıntı Senaryo	Ücretler	Bütçe Dengesi		Enflasyon Beklentisi
		Dengesi	Devaluasyon	
10	618.579	-4105812.538	6.938147568	3.29101879

Şekil 5.8 ve 5.9 incelendiğinde 10 no'lu senaryonun içinde bulunduğu 4 no'lu senaryodaki 1 / 5 / 6 / 12 ve 27 no'lu senaryolarla; 2 no'lu senaryodan ise 25 no'lu senaryo ile ilişkili olduğu görülür. Sözkonusu bu ayrıntı senaryoların Tablo 6.9'da verilen değerlerine bakıldığında ise bu durumdan geçilecek olan olası durumda enflasyon beklentisinin mutlaka yükselmesi beklenmektedir, zira olası 6 görüntünün hepsinde de bu değer yükselmiştir. Bütçe açığının ise büyük olasılıkla düşeceği söylenebilir çünkü 6 değerden dördünde düşme eğilimindedir. Ücretler için ise 6 değerden üçünde düşüş, üçünde de yükseliş eğilimi gözlemlendiğinden bir şey söylemek güçtür. Devaluasyonun ise yine büyük olasılıkla düşmesi beklenmektedir. Eylül verileri incelendiğinde enflasyon beklentisinin beklendiği gibi yükseldiği ve bütçe açığının da yine beklendiği gibi azalmış olduğu görülmüştür. Ücretler , olsı altı durumdan üçünde ortaya çıktığı gibi düşmüştür. Sadece devaluasyon büyük olasılıkla beklenen azalışı göstermemiş; hemen hemen sabit bir değerde kalmıştır.

Son bir sağlama olarak Ekim 1998 ve kontrolü için de Kasım 1998 değerleri incelenmiştir. Buna göre ilgili değerler, aşağıdaki gibi belirlenmiştir.

Gelecek görüntüleri içinden, Ekim 1998'in verilerine en yakın değerler 11 no'lu ayrıntı senaryoya aittir. Bir önceki örnekte olduğu gibi yine korelasyon analizi yapılmış ve en yüksek korelasyonu sözkonusu ayrıntı senaryo elde etmiştir. 11 no'lu senaryoya ait veriler de aşağıda verilmiştir.

Tablo 6.15 Üçüncü Örnek İçin Veriler

Dönem	Ücretler	Bütçe Dengesi	Devaluasyon	Enflasyon Beklentisi
Eki.98	604.0	-3010866	1.210876	8.381909
Kas.98	611.0	-3078454	5.609102	5.946186

Tablo 6.16 Üçüncü Örnek İçin Kontrol Verileri

Ayrıntı Senaryo	Ücretler	Bütçe Dengesi	Devaluasyon	Enflasyon Beklentisi
11	697.476	-3469388.881	2.640689089	6.94234779

Şekil 5.8 ve 5.9 incelendiğinde 11 no'lu senaryonun içinde bulunduğu 2 no'lu senaryodaki 7 / 8 / 13 / 15 / 20 / 22 / 24 ve 26 no'lu senaryolarla; 3 no'lu senaryodan ise 4 / 16 ve 23 no'lu senaryolar ile ilişkili olduğu görülür. Söz konusu bu ayrıntı senaryoların Tablo 6.9'da verilen değerlerine bakıldığında ise bu durumdan geçilecek olan olası durumda senaryoların çoğunluğunun sağladığı değerler uyarınca ücretlerin ve enflasyon beklentisinin düşmesi; bütçe açığının ve devaluasyonun ise yükselmesi beklenmektedir. Kasım 1998 verileri incelendiğinde enflasyon beklentisinin beklendiği gibi düştüğü; bütçe açığının ve devaluasyonun ise yine beklendiği gibi yükseldiği görülmüştür. Sadece ücretler, çoğunluk değerlerine uymamış ve beklenilenin aksine yükselmiştir.

Yukarıda kontrol amaçlı verilen örneklerden de görülebileceği gibi, yapılan bu dinamik senaryo analizi çalışması gelecekteki belirsizlikleri büyük ölçüde hazırlıklı olunmasını sağlamak ve yön çizmek için etkin bir biçimde kullanılabilir. Temel senaryoların içerdikleri ayrıntı senaryolar gelecekte karşılaşılabilecek durumları daha net ve çeşitli olarak ortaya koyabildikleri için oldukça gerekli ve bir o kadar da yararlıdırlar. Onlar sayesinde, içinde bulunulan durumdan hangi olası durumlara geçişlerin olabileceği, bu geçiş durumlarından hangilerinin senaryo içi, hangilerinin ise senaryo dışı değişimlere yol açabileceği üzerinde fikir yürütülebilir. Bunun için, ülkenin mevcut durumda içinde bulunduğu durumu belirlemek için 4 temel göstergenin mevcut durumdaki değerleri bulunup, içinde bulunulan duruma en yakın senaryo belirlenebilir. Daha sonraya, bu senaryodan geçiş yapılabilecek diğer senaryolar belirlenip, ilgili stratejiler hazırlanabilir. Bunun yanısıra; geçiş yapılması istenen senaryolar üzerinde de durulup, çizilmesi gereken yön üzerinde durulabilir. Bunları yaparken %100 bir kesinliğin olmayacağı açıktır. Ancak, zaten senaryo

analizinin özünde de bir kesinlikten çok gelecekteki belirsizliklere büyük ölçüde hazırlıklı olunması için bir yol gösterme mantığı vardır. Bu yol göstermeyi de, ortaya konan dinamik senaryo analizi çalışması içerdği temel senaryolar ve bu temel senaryoların da kapsadığı ayrıntı senaryolar ile etkin bir biçimde yerine getirmektedir.



7 SONUÇ VE ÖNERİLER

Strateji belirleme; kişiler, şirketler ve daha büyük ölçekte de ülkeler için oldukça önemli ama bir o kadar da zorlu bir süreçtir. Günümüz dünyasında bu süreci zorlaştıran en önemli etken, geleceğin belirsizliği, sürprizlere açık oluşu ve beklenmedik gelişmeler içermesidir. Söz konusu bu zorluğun üstesinden gelmenin ve strateji geliştirmenin en etkin yolu ise gelecekteki belirsizlikleri gidermeye ve bu uzun vadeli belirsizliklerle etkin bir şekilde başedebilmeye yönelik olarak 1970'lerden beri çeşitli organizasyonlar tarafından kullanılan senaryo analiz çalışmalarını uygulamaya koymaktır. Senaryo analizi geleneksel tahmin tekniklerinden oldukça farklıdır. Zira, senaryo analizi geçmiş verilerden yola çıkarak gelecekle ilgili tahminlerde bulunmak yerine organizasyonun çevresindeki birbiriyle ilişkili unsurların olası gelişmelerinin gözönünde tutularak bir organizasyonun çevresinin, olası gelecek görüntü ve/veya görüntülerinin tanımlanması sürecidir. Senaryo analizinin amacı gelecekle ilgili belirsizlikleri çözmek değil, bunun yerine gelecekte karşılaşılabilecek olan farklı durumlara önceden hazırlıklı olabilmektir.

Bu karmaşık ve belirsiz çevre ile ilgili analizler yapıp farklı senaryolar üretmenin alternatif ve etkin bir yolu da Powell ve Coyle (1997) tarafından ortaya konan EFAR yaklaşımıdır. Söz konusu yaklaşım, geleneksel senaryo analiz yaklaşımındaki birbirinden ayırık duran kısıtlı sayıda senaryo üretmeye alternatif olarak çok sayıda ve birbiriyle ilişkili birçok gelecek görüntüsü ile çalışmayı önermektedir. Gelecekle ilgili durumların, birbirleriyle çift yönlü olarak ilişkilendirmiş oldukları bir ağ şeklinde ortaya konulmalarını sağlayan ve geleneksel senaryo analizine göre iyileştirilmiş yeni bir yapı oluşturan EFAR; bu şekilde, içerik olarak zengin bir gelecek görüntüsü de çizmektedir. Ancak geleneksel senaryo analizine alternatif olarak ortaya konan bu yaklaşım, bir süreç tanımlasa da; yoğun bir şekilde öznel bilgiye dayanmakta, bu da yöntemin çok önemli bir eksikliği olarak ortaya çıkmaktadır.

Tez kapsamında, EFAR yaklaşımının temeli sayılabilecek “çok sayıda ve birbiriyle ilişkili gelecek görüntüleri üretmek ve bunlarla gelecekteki belirsizliklerin üstesinden gelmeye çalışmak” mantığı benimsenmiştir. Ancak izlenen her aşamada farklı ve nesnel bilgiye dayalı bir dizi yaklaşım ve yöntem kullanılarak, analiz hem dinamik boyutunu korumuş hem de özgün ve geleneksel senaryo analizine üstünlükleri olan yeni bir biçim almıştır.

Tez kapsamında ortaya konan çalışmada farklı uzmanların bir konu üzerindeki görüşlerini sistematik bir şekilde ortaya koymak için bilişsel haritalardan; tahmin ve kümeleme analizleri için ise yoğun olarak yapay sinir ağlarından yararlanılmıştır. Bu bağlamda tezde önerilen dinamik senaryo analiz sürecinin adımları ve ortaya koyduğu üstün ve özgün yönler aşağıda aşama aşama irdelenmektedir.

1. Temel özelliklerin listelenmesi : Önerilen yeni ve dinamik senaryo analizinin ilk aşamasında incelenilen konu ile ilgili uzmanların görüşlerinin ortaya konması için bilişsel harita yaklaşımı kullanılması önerilmektedir. Böylece hem incelenilen konu ile ilgili uzman görüşlerinin ortaya konması sistematikleştirilmekte hem de birden fazla uzmanın görüşünün toplu bilişsel harita yaklaşımı ile bir bütün olarak ortaya konmasına olanak tanınmaktadır. Bunun yanı sıra, Wang'ın (1996) önerisiyle bilişsel haritaların incelenmesinde önemli bir engel oluşturan döngülerin varlığı da sorun olmaktan çıkarılmış, aksine döngüler içeren bilişsel haritaların analizine yeni bir boyut kazandırılmıştır.

Daha sonraysa yapay sinir ağları ile, toplu bilişsel harita aracılığıyla ortaya konan ve incelenilmesi gereken kavramlardan en önemlilerinin belirlenmesi için bir tahmin süreci kullanılması önerilmektedir. Böylece karmaşık konuların kısıtlı sayıda temel özellikle ortaya konmasının zorluğu ortadan kaldırılmış olmaktadır.

Bu aşamada yapılan tahminde amaç her ne kadar en önemli kavramları belirlemek olsa da; yapay sinir ağları ile yapılan tahmin sonuçlarının oldukça etkin olduğu ve diğer tekniklerle yapılan tahminlerden elde edilen sonuçlarla karşılaştırıldığında da yapay sinir ağlarının ciddi ölçüde daha iyi tahmin yaptığı da belirlenmiştir.

2. Gelecek görüntülerini oluşturacak tüm bileşimlerin ortaya konması: Bu aşamada, bir önceki aşamada yapay sinir ağlarında kullanılan veriler ve bir excel add-in programı olan SIM.XLA yardımıyla geleceğe dair çok sayıda gelecek görüntüsü

üretilmesi önerilmektedir. Bu adım, önerilen yöntemin hem geleneksel senaryo analizinden hem de EFAR'dan farklılaştığı en önemli noktalardan biridir. Zira geleneksel senaryo analizi kısıtlı sayıda senaryo ile çalışırken, EFAR yaklaşımı da tamamen öznel bilgiye dayanarak ortaya koyduğu sektör-seviye çiftleri aracılığıyla bu gelecek görüntülerini oluşturmaktadır.

3. Anlamsız bileşimlerin elenmesi: Tez çalışmasında anlamsız bileşimlerin reddi için önce yapay sinir ağları ile kümeleme çalışması yapılması; daha sonra ise kümeleme analizi yardımıyla benzer olan durumların biraraya toplanmış gruplarına korelasyon analizi uygulayıp aralarında anlamlı ilişki olmayanların elenmesi yoluna gidilmesi önerilmektedir. Böylece uzman yargısının kişiselliği olmaksızın anlamsız gelecek görüntülerinin ortadan kaldırılması sağlanmaktadır.

4. Olurlu bileşimlerin kümelenmesi: Tez kapsamında yapay sinir ağlarının yoğun şekilde kullanılması sözkonusudur. Tıpkı bir önceki aşamada olduğu gibi bu aşamada da olurlu bileşimlerin kümelenmesi için yapay sinir ağları yardımıyla kümeleme analizi yapılması önerilmektedir. Böylece olası kümelemelerin EFAR'daki gibi el ile yapıldığında gözden kaçabilme olasılığının da engellenmesi sağlanmaktadır.

5. Geçiş matrisinin oluşturulması: Bu aşamada SPSS yardımıyla kümeleme çalışması yapılması ve ortaya çıkan dendrogram aracılığı ile hangi durumların birbirleriyle ilişkili olduklarının uzman yargısına gerek duyulmadan belirlenmesi önerilmektedir. Böylece gelecek görüntülerinin birbirleri ile olan bağlantıları ortaya konarak hem geleneksel senaryo analizinden farklılaşma sağlanmakta, hem de bu ilişkilerin EFAR yaklaşımında olduğu gibi sadece uzman yargısı ile belirlenmesi sorununu da ortadan kaldırılmaktadır.

6. Matrisin çizgelere aktarılması: Tez çalışmasının son aşamasında da uzman yargısının öznelliğinden uzak bir şekilde temel senaryoları belirleyebilmek için yine yapay sinir ağları yardımı ile kümeleme analizi yapılması ve temel senaryolar bu şekilde belirlendikten sonra yönlü çizgelere aktarılması önerilmektedir.

Bu tez kapsamında yapılan çalışma aracılığıyla önerilen “Yapay Sinir Ağları Yardımı ile Dinamik Bir Senaryo Analizi” adlı çalışma sürecinin yukarıda özet şekilde ortaya konmaya çalışılan en önemli özelliği; öznel bilgiye gereksinimi en aza indirgeyerek birbirleri ile ilişkili gelecek görüntüleri yardımıyla gelecekteki

belirsizlik ve karmaşıklığa rağmen strateji geliştirmeye yardımcı olacak senaryolar ortaya koymaktır. Böylece kısıtlı sayıda olan ve birbirinden ayrık şekilde incelenen senaryolar yerine, çok sayıda olan ve birbiriyle ilişkili senaryolar ile çalışma özelliğini temel mantık olarak benimseyen; bunun yanısıra bilişsel haritalar ve yapay sinir ağları yaklaşımları yardımıyla etkin bir şekilde senaryo üreten bir yaklaşım önerilmektedir.

Çalışmanın geliştirilmesine yönelik öneriler ise aşağıdaki gibi sıralanabilir.

Çalışma boyunca yapay sinir ağlarının kullanımını gerektiren aşamalarda yararlanılan MATLAB, test sürecini kullanıcının inisiyatifine bıraktığından süreç uzamaktadır. Bunun yerine test işlemini kendi işleyişi içinde gerçekleştiren bir yazılımdan yararlanmak sürecin işleyişini hızlandırıp daha etkin bir hale getirilebilir.

Tez kapsamında yapılan her çalışmada örnek uygulama olarak enflasyon konusu alınmış, yaklaşımın yeni hali bu konu üzerinde denenmiş ve etkinliği test edilmiştir. Bu aşamadan sonra senaryo analizi çalışması yapmak isteyen tüm organizasyonlarda tezde önerilen yaklaşımın kullanılabileceği açıktır.

İlk aşama olan temel özelliklerin belirlenmesi; çalışmanın en çok zaman alıcı kısmı olsa da; tüm çalışmanın temelini oluşturduğundan üzerinde titizlikle durulması gereken bir aşama olduğu açıktır. Bunun yanısıra bu aşamadaki tahmin çalışması başlıbaşına ayrı bir çalışma olarak ele alınabilir ve her 3 ayda bir tekrarlanıp, enflasyon için öngörülerde bulunulabilir.

Yapılan çalışmada sayısal verilere sahip olmayan veriler yöntemin ilk aşamasında elenmiş; sürece sayısal verilere sahip değişkenlerle devam edilmesine karar verilmiştir. Ancak bu karar, sayısal verilere sahip olmayan değişkenlerin enflasyon üzerindeki olası önemli etkilerinin atlanması sonucunu doğurabilir. Bu nedenle; yapılan tahminin ayrıntılı bir şekilde incelenmesi ve sayısal olmayan verilerin tahmine olan olası etkilerinin önem derecelerinin belirlenmesi yararlı olabilir.

Sonuç olarak, önerilen senaryo analiz yaklaşımının özgün, geleneksel senaryo analiz çalışmalarına yeni ve dinamik bir boyut kazandıran sürecinin gelecekteki belirsizliği ve karmaşıklığı anlamak ve hazırlıklı olmak isteyen tüm organizasyonlarca kullanılabileceği söylenebilir.

KAYNAKLAR

- Alon, I., Qi, M., Sadowski, R.J., 2001. Forecasting Aggregate Retail Sales: A Comparison Of Artificial Neural Networks And Traditional Methods, *Journal Of Retailing And Consumer Services*, **8**, 147-156.
- Alpaydın, E., Altinel, İ.K., Aras, N., 1995. Parametric Distance Functions vs. Nonparametric Neural Networks For Estimating Road Travel Distances, *European Journal Of Operational Research*, **92**, 230-243.
- Axelrod, R., 1976a. Cognitive Mapping, in *Structure of Decision: The Cognitive Maps of Political Elites*, pp.5-13, Eds. Axelrod R., Princeton University Press.
- Axelrod, R., 1976b. The Mathematics of Cognitive Maps, in *Structure of Decision: The Cognitive Maps of Political Elites*, pp.343-348, Eds. Axelrod R., Princeton University Press.
- Banxia Software Limited, October 1996. Decision Explorer 3 Reference Manual, University of Strathclyde, Scotland.
- Barnard, E., 1992. Optimization For Training Neural Nets, *IEEE Transactions On Neural Networks*, **3/2**, 232-240.
- Battiti, R., 1992. First-And Second-Order Methods For Learning: Between Steepest Descent And Newton's Method, *Neural Computation*, **4**, 141-166.
- Blum, A., 1992. Neural Networks In C++, John Wiley& Sons Inc., USA.
- Bood, R. and Postma, T., 1997. Strategic learning with scenarios, *European Management Journal*, **15/6**, 663-647.
- Becker, H.S., 1983. A tool of growing importance to policy analysts in government and industry, *Technological Forecasting and Social Change*, **23**, 95-120.
- Bonnicksen, T.M., 1992, EZ-Impact: The judgement-based systems modeling and decision analysis program, User Manual.
- Bunn, D.W. and Salo, A.A., 1993. Forecasting with scenarios", *European Journal of Operational Research*, **68**, 291-303.
- Chandra, R., Newburry, W., 1997. A Cognitive Map of the International Business Field, *International Business Review*, **6/4**, 387-410.

- Chaudhury, A, Stahl, D.O., Whinston, A.B.**, 1994. The Economic Foundation for Neural Computing Systems in, *Advances in AI in Economics, Finance and Management* , pp.1-22, Eds. Johnson J.D., Whinston A.B., JAI Press Inc
- Chen, S., Mangiameli, P., West, D.**, 1995. The Comparative Ability Of Self-Organizing Neural Networks To Define Cluster Structure, *Omega Int. J. Mgmt. Sci.* **23/3**, 271-279.
- Chiang, W-C, Urban, T.L., Baldridge, G.W.**, 1996. A Neural Network Approach to Mutual Fund Net Asset Value Forecasting, *Omega Int. J. Mgmt. Sci.*, **24/2**, 205-215.
- Coyle, R.G., Crawshay, R., Stton, L.**, 1994. Futures Assessment By Field Anamoly Relaxation, *Futures*, **26/1**, 25-43.
- Curram, S.P., Mingers, J.**, 1994. Neural Networks, Decision Tree Induction And Discriminant Analysis: An Emprical Comparison, *J.Of Opl.Res.Soc.*, **45/4**, 440-450.
- Curry, B., Morgan, P.**, 1996. Neural Networks: A Need For Caution, *Omega Int.J.Mgmt.Sci.*, **25/1**, 123-133.
- Eden, C, Ackermann, F., Cropper, S.**, 1992. The Analysis of Cause maps, *Journal of management Studies*, **29/3**, 309-323.
- Frean, M.**, 1990. The Upstart Algorithm: A Method For Constructing And Training Feedforward Neural Networks, *Neural Computation*, **2**, 198-209.
- Gappert, G.**, 1973. The Development of a Pattern Model For Social Forecasting, *Futures*, **August**, 367-382.
- Gately, E.**, 1996. Neural Networks for Financial Forecasting, John Wiley & Sons, Inc, USA.
- Godet, M.**, 1994. From anticipation to action, Unesco, France.
- Gruca, T.S, Klemz, B.R.**, 1997. Using Neural Networks To Identify Competitive Market Structures From Aggregate Market Response Data, *Omega Int.J.Mgmt.Sci.*, **26/1**, .49-62.
- Hardgrave, B.C., Wilson, R.L., Walstrom, K.A.**, 1994. Predicting Graduate Student Success: A Comparison Of Neural Networks And Traditional Techniques, *Computers Ops.Res.*, **21/3**, 249-263.
- Hart, A.**, 1992. Using Neural Networks For Classification-Some Experiments On Datasets And Practical Advice, *J.Opl.Res.Soc.*, **43/3**, 215-226.

- Hawley, D.D., Johnson, J.D.**, 1994. ANN: Past, Present and Future, in *Advances in AI in Economics, Finance and Management*, pp.1-22, Eds. Johnson J.D., Whinston A.B.. JAI Press Inc.
- Hertz, J., Krogh, A., Palmer, R.G.**, 1991. Introduction to the Theory of Neural Computation, Addison-Wesley Publishing Company, USA.
- Hruschka, H.**, 1993. Determining Market Response Functions by Neural Network Modeling: A Comparison to Econometric Techniques, *European Journal of Operational Research*, **66**, 27-35.
- Huang, S-C, Huang, Y-F**, 1990. Learning Algorithms For Perceptrons Using Back-Propagation With Selective Updates, *IEEE Control Systems Magazine*, **April**, 56-61.
- Hwang, C.L., Lin, M.J.**, 1987. Group Decision Making Under Multiple Criteria, Springer-Verlag.
- Huss, W.R. and Honton E.J.**, 1987. Scenario planning-what style should you use?. *Long Range Planning*, 20/4, 21-29.
- Jacobs, R.A.**, 1988. Increased Rates Of Convergence Through Learning Rate Adaptation, *Neural Networks*, **1**, 295-307.
- Klein, B.D., Rossin, D.F.**, 1999. Data Quality In Neural Network Models: Effect Of Error Rate And Magnitude Of Error On Predictive Accuracy, *Omega Int.J.Mgmt.Sci.*, **27**, 569-582.
- Kuo, R.J., Chen, C.H., Hwang, Y.C.**, 2001. An Intelligent Stock Trading Support System Through Integration Of Genetic Algorithm Based Fuzzy Neural Network And Artificial Neural Network, *Fuzzy Sets And Systems*, **118**, 21-45.
- Kwahk, K.Y., Kim, Y.G.**, 1999. Supporting Business Process Redesign Using Cognitive Maps, *Decision Support Systems* **25/2**, 155-178.
- Lee, C.W., Park, J-A.**, 2001. Assessment Of HIV/AIDS-Related Health Performance Using An Artificial Neural Network, *Information & Management*, **38**, 231-238.
- Lee, S., Courtney, J.F., O'Keefe.** 1992. A System For Organizational Learning Using Cognitive Maps, *OMEGA*, **20/1**, 23-36.
- Leemhuis, J.P.**, 1985. Using scenarios to develop strategies, *Long Range Planning*, 18/2, 30-37.
- Leu, S-S, Chen, C-N, Chang, S-L**, 2001. Data Mining For Tunnel Support Stability: Neural Network Approach, *Automation In Construction*, **10**, 429-441.

- Lippmann, R.P.**, 1987. An Introduction To Computing With Neural Nets, *IEEE ASSP Magazine*, **April**, 4-22.
- Lopez, G., Rubio, M.A., Martinez, M., Batlles, F.J.**, 2001. Estimation Of Hourly Global Photosynthetically Active Radiation Using Artificial Neural Network Models, *Agricultural And Forest Meteorology*, **107**, 279-291.
- Luk, K.C., Ball, J.E., Sharma, A.**, 2001. An Application Of Artificial Neural Networks For Rainfall Forecasting, *Mathematical And Computer Modelling*, **33**, 683-693.
- Mangiameni, P., Chen, S.K., West, D.**, 1996. A Comparison Of SOM Neural Network And Hierarchical Clustering Methods *European Journal Of Operational Research*, **93**, 402-417.
- Masson, E., Wang, Y-J**, 1990. Introduction to Computation and Learning in Artificial Neural Networks, *EJOR*, **47**, 1-28.
- Masters, T.**, 1993. Practical Neural Network Recipes in C++, Academic Press. USA.
- Morrison, J.L. and Wilson I.**, 1997. Analysing environments and developing scenarios in uncertain times in *Planning and Management for a Changing Environment* Eds. Peterson, M. W., Dill, D. D., Mets, L. A., and Associates, San Francisco.
- Nozicka, G.J., Bonham, G.M., Shapiro, M.J.**, 1976. Simulation Techniques, in *Structure of Decision: The Cognitive Maps of Political Elites*, pp.349-359, Eds. Axelrod R., Princeton University Press.
- Önsel, Ş.**, 1995. Yeni Bir Yöneylem Araştırması Yaklaşımı: Bilişsel Haritalar. *Yüksek Lisans Tezi*, İTÜ Fen Bilimleri Enstitüsü.
- Özen, Ü.Y.**, 2000, Modeling and Analyzing Strategic Thoughts Using Cognitive Mapping, *Ph.D. Thesis*, İTÜ Fen Bilimleri Enstitüsü.
- Pamuk, G. Erkut, H., Ülengin, F., Ülengin, B., Akgüç, Ö., Alpay, Y. ve Koşma, H.**, 1997. Stratejik yönetim ve senaryo tekniği, İrfan Yayıncılık, İstanbul.
- Piramuthu, S., Kuan, C-M, Shaw, M.J.**, 1993. Learning Algorithms for Neural-Net Decision Support, *ORSA Journal on Computing*, **5/4**, 361-373.
- Powell, J. H.**, 1997. An application of a network-based futures method to strategic business planning, *Journal of Operational Research Society*, **48**, 857-872.
- Powell, J.H., Coyle, R.G.**, 1997. A Network-Based Futures Method for Strategic Business Planning, *Journal of Operational Research Society*, **48**, 793-803.

- Raubitschek, R.S.**, 1988. Multiple Scenario Analysis and Business Planning. *Advances in Strategic Management*, 5, 181-205.
- Rhyne, R.**, 1974. Technological Forecasting Within Alternative Whole Futures Projections, *Technological Forecasting and Social Change*, 6, 133-162.
- Rhyne, R.**, 1981. Whole Pattern Futures Projection Using Field Anamoly Relaxation, *Technological Forecasting and Social Change*, 19, 331-360.
- Roberts, S.**, 1976. Strategy for the Energy Crisis: the Care of Commuter Transportation Policy, , in *Structure of Decision: The Cognitive Maps of Political Elites*, pp. 142-167, Eds. Axelrod R., Princeton University Press.
- Rodriguez, F.F., Martel, C.G., Rivero, S.S.**, 2000. On The Profitability Of Technical Trading Rules Based On Artificial Neural Networks: Evidence From The Madrid Stock Market, *Economic Letters*, 69, 89-94.
- Rumelhart, D.E., Hinton, G.E., Williams, R.J.**, 1986. Learning Representations By Back-Propagating Errors, *Nature*, 323/9, 533-536.
- Salchenberger, L.M., Cinar, E.M., Lash, N.A.**, 1992. Neural Networks:A New Tool For Predicting Thrift Failures, *Decision Sciences*, 23, 899-916.
- Schalkoff, R.J.**, 1997. Artificial Neural Networks, McGraw-Hill, Usa.
- Schnaars, S.P.**, 1987. How to Develop and Use Scenarios, *Long Range Planning*, 20/1, 105-114.
- Schoemaker, P.J.H.**, 1995. Scenario Planning: A Tool for Strategic Thinking, *Sloan Management Review*, Winter, 25-40.
- Schoemaker, P.J.H.**, 1993. Multiple Scenario Development: Its conceptual and Behavioral Foundation, *Strategic Management Journal*, 14, 193-213.
- Schoemaker, P.J.H.**, 1991. When and How to Use Scenario Planning: A Heuristic Approach with Illustration, *Journal of Forecasting*, 10, 549-56.
- Sharda, R.**, 1994. Neural Networks for the MS/OR Analyst: An Application Bibliography, *Interfaces*, 24/2, 116-130.
- Soylu, M., Özdemirel, N.E., Kayaligil, S.**, 2000. A Self-Organizing Neural Network Approach For The Single AGV Routing Problem, *European Journal Of Operational Research*, 121, 124-137.

- Stam, A., Sun, M., Haines, M.,** 1996. Artificial Neural Network Representations For Hierarchical Preference Structures, *Computers Ops. Res.*, **23/12**, 1191-1201.
- Tam, K.Y., Kiang, M.Y.,** 1992. Managerial Applications Of Neural Networks: The Case Of Bank Failure Predictions, *Management Science*, **38/7**, 926-947.
- Tam, K.Y.,** 1991. Neural Network Models And The Prediction Of Bank Bankruptcy, *Omega Int.J.Of Management Science*, **19/5**, 429-445.
- Tang, Z., Fishwick, P.A.,** 1993. Feedforward Neural Nets as Models for Time Series Forecasting, *ORSA Journal on Computing*, **5/4**, 374-385.
- Teixeira, J.C., Rodrigues, A.J.,** 1996. An Applied Study On Recursive Estimation Methods, Neural Networks And Forecasting, *European Journal Of Operational Research*, **101**, 406-417.
- Tenaglia, M., Noonan, P.,** 1992. Scenari-Based Strategic Planning: A Process for Building Top Management Consensus, *Planning Review*, **March/April**, 12-19.
- The Mathworks, Inc.,** January 1994. Neural Network Toolbox for use with MATLAB, User's Guide.
- Turner, C.H.,** 1995. Strategic Dilemmas Occasioned by Using Alternative Scenarios of the Future, in *Developing Strategic Thought*, Eds. Garratt B., McGraw-Hill, Cambridge.
- Venkatachalam, A.R., Sohl, J.E.,** 1999. An Intelligent Model Selection And Forecasting System, *Journal Of Forecasting*, **18**, 167-180.
- Wang, S.,** 1996. A Dynamic Perspective of Differences Between Cognitive Maps, *Journal of Operational Research Society*, **47**, 538-549.
- Weinstein, B.,** 1995. The Use of Scenerio Thinking: Can a Scenerio a Day Keep the Business Doctor Away? in *Developing Strategic Thought*, Eds. Garratt B., McGraw-Hill, Cambridge.
- White, H.,** 1989. Learning In Artificial Neural Networks: A Statistical Perspective, *Neural Computation*, **1**, 425-464.
- Wollenberg, E., Edmunds, D., Buck, L.,** 2000. Using Scenarios To Make Decisions About The Future: Anticipatory Learning For The Adaptive Co-Management Of Community Forests, *Landscape and Urban Planning*, **47**, 65-77.
- Wrightson, M.T.,** 1976.. The Documentary Coding Method. , in *Structure of Decision: The Cognitive Maps of Political Elites*, pp. 291-331, Eds. Axelrod R., Princeton University Press.

- Yoon, Y., Swales, G., Margavio, T.M., 1993.** A Comparison of Discriminant Analysis Versus Artificial Neural Networks. *Journal of Operational Research*, **44/1**, 51-60.
- Zahedi, F., 1991.** An Introduction To Neural Networks And A Comparison With Artificial Intelligence And Expert Systems, *Interfaces*, **121/2**, 25-38.
- Zhang, G., Hu, M.Y., 1998.** Neural Network Forecasting Of The British Pound/US Dollar Exchange Rate, *Omega Int.J.Of Mgmt.Science*, **26/4**, 495-506.



EKLER



EK A

Tablo A.1 Ocak 1994-Aralık 1998 İçin Veriler

	Faiz (%)	Döviz Kuru (\$)	Para Arzı (M2)	Sıcak Para Hareketleri (Milyon TL)	Ücretler (Bin TL/saat)	Kapasite Kullanım Oranı (%)	Kamu Borçları (Milyon TL)
Ocak 94	67.7	15194.6	277,501	-191	39.28	83	382142.8
Şubat 94	87.4	17740.4	280.642	-573	40.33	76.5	408659
Mart 94	87.1	20628.1	295.423	63	47.15	75.5	437015.1
Nisan 94	131	32222.8	304.716	-766	44.23	71	467338.8
Mayıs 94	132	33900.1	378.012	-744	47.05	69.5	499766.5
Haziran 94	122	31746	441.230	-790	44.92	70	534444.4
Temmuz 94	79.3	31031.9	526.748	-892	45.23	71	571528.4
Ağustos 94	67.5	31727.5	558.518	-124	45.26	72.9	611185.7
Eylül 94	67.3	33984.5	559.937	-624	49.30	78.7	653594.8
Ekim 94	62.5	34952.1	562.997	-266	54.06	76.1	698946.5
Kasım 94	74.5	36331	565.402	240	56.62	74.9	747445
Aralık 94	77.3	37477.8	604,136	-460	61.05	76.8	799308.8
Ocak 95	87	40237.4	621.876	830	63.44	74.8	835560.5
Şubat 95	87.4	41109	680,579	1224	68.03	73	873456.6
Mart 95	78.7	41866.8	753.909	1898	74.03	76.6	913071.5
Nisan 95	73.7	42411.6	828.929	460	74.34	78.9	954483.1
Mayıs 95	73.1	43173.8	905.456	486	80.26	79.3	997772.8
Haziran 95	73.1	43293.5	945.864	575	75.76	81.6	1043026
Temmuz 95	69.1	44570.8	1,091,908	-35	79.23	82.9	1090332
Ağustos 95	68.8	46735.1	1,097.032	560	79.96	81.5	1139783
Eylül 95	69.1	47892.7	1,112.633	33	86.19	84.6	1191477
Ekim 95	69.4	50125.1	1,113.786	-14	91.00	80.6	1245515
Kasım 95	78.2	52517.5	1,180.854	-406	98.00	79.6	1302004
Aralık 95	83.9	56872	1,256.332	-1898	105.00	82.4	1361055
Ocak 96	85.5	60594.3	1,284.034	1158	107.00	80	1459545
Şubat 96	84.8	64214.4	1,407.026	575	119.00	78.4	1565218
Mart 96	82.7	68447.5	1,425.968	-111	121.00	76.7	1678543
Nisan 96	79.7	72725.1	1,643.130	909	136.00	77.5	1800072
Mayıs 96	79.4	76919.6	1,686.551	284	135.00	82.2	1930401
Haziran 96	79.1	79877.9	1,825.307	639	135.00	81.7	2070165
Temmuz 96	79.6	82910.5	1,897.442	-30	144.00	80	2220049

TC YATIRIM MENKUL DEĞERLER A.Ş.
BODURTAŞ YATIRIM MENKUL DEĞERLER A.Ş.

	Faiz (%)	Döviz Kuru (\$)	Para Arzı (M2)	Sıcak Para Hareketleri (Milyon TL)	Ücretler (Bin TL/saat)	Kapasite Kullanım Oranı (%)	Kamu Borçları (Milyon TL)
Ağustos 96	79.7	85120.9	2,123.704	366	159.00	79.3	2380784
Eylül 96	79.6	89070	2,253.409	771	168.00	79.5	2553157
Ekim 96	79.5	93956.8	2,374.836	298	174.00	81.2	2738010
Kasım 96	79.6	98727.2	2,532.918	902	177.00	77	2936246
Aralık 96	79.7	104968	2,801.675	184	183.00	79.7	3148836
Ocak 97	77.2	112565	2,921.288	-328	200.00	78.4	3335589
Şubat 97	76.6	119480	3,077.513	-78	220.00	77.3	3533253
Mart 97	76.5	125160	3,232.451	241	226.00	80.8	3742630
Nisan 97	76.6	131220	3,441.982	601	255.00	77.6	3964414
Mayıs 97	76.8	137426	3,579.704	1166	254.00	82.6	4199342
Haziran 97	77.4	144426	3,768.239	281	260.00	81	4448190
Temmuz 97	79.2	153563	4,046.317	194	271.00	80.8	4711786
Ağustos 97	82.6	163775	4,201.950	203	308.00	82.4	4991001
Eylül 97	82.2	170562	4,484.355	162	323.00	86.6	5286763
Ekim 97	82.6	178335	4,908.302	134	346.00	79.8	5600051
Kasım 97	82.9	187472	4,931.086	93	344.00	84	5931904
Aralık 97	83.2	200010	5,264.529	-908	351.00	78.8	6283423
Ocak 98	82.5	212159	5,798.157	874	413.00	75.8	6613403
Şubat 98	82.8	223770	5,918.861	222	416.00	78.1	6960712
Mart 98	82.7	235928	5,985.260	1220	457.00	80.5	7326260
Nisan 98	81.9	246084	6,437.686	31	511.00	77.4	7711005
Mayıs 98	81.2	252522	7,119.512	937	490.00	82.1	8115955
Haziran 98	77.6	261310	7,781.176	117	474.00	78.7	8542171
Temmuz 98	71.3	268917	8,570.950	-838	521.00	81.1	8990771
Ağustos 98	73	274574	8,668.649	381	548.00	79.4	9462929
Eylül 98	81.7	275950	9,014.456	-4290	563.00	81.8	9959883
Ekim 98	82.2	279291	9,700.232	3770	604.00	80	10482934
Kasım 98	81.8	294957	10,162.443	482	611.00	79.2	11033455
Aralık 98	82.8	307647	10,856.763	-305	624.00	74.4	11612886

	Bütçe Açığı (MilyonTL)	İstihdam (Kişi)	Net Dış Varlık Girişi (MilyonTL)	Devalüasyon (%)	Enflasyon Beklentisi (%)	Enflasyon (%)
Ocak 94	-4377	534423	8031.8	8.0568	6.508602	4.40895
Şubat 94	-19132	523790	-10181	16.754	4.81145	6.00987
Mart 94	-51273	515757	-28821.8	16.278	4.667155	5.180382
Nisan 94	-55533	509912	-77031.2	56.208	4.899289	24.70521
Mayıs 94	-49198	522391	-85969.5	5.2053	2.977009	9.952342
Haziran 94	-41193	512009	-65012.5	-6.354	1.7593	0.912989
Temmuz 94	-55378	506415	-47658.5	-2.25	2.504643	1.72721
Ağustos 94	-58284	510753	-21152.5	2.2416	3.489671	2.03252
Eylül 94	-68122	523211	-23586.5	7.1139	6.375481	7.158108
Ekim 94	-74615	516556	-20908.3	2.8473	7.014894	9.49202
Kasım 94	-54179	507466	-27328.3	3.945	5.505625	8.095077
Aralık 94	-152181	497685	-6694.2	3.1566	3.572368	6.336452
Ocak 95	5531	500822	10499.5	7.3633	6.356888	6.774931
Şubat 95	-36328	496895	66915.4	2.166	5.0071	5.74739
Mart 95	-53940	499301	87845.5	1.8436	4.93811	4.100837
Nisan 95	-128296	513123	103442.1	1.3011	10.94899	6.438668
Mayıs 95	-115352	533506	132421	1.7972	5.184154	3.20527
Haziran 95	-113052	539450	155071.3	0.2772	1.078269	2.006017
Temmuz 95	-103320	534975	175895.4	2.9505	2.642862	2.909578
Ağustos 95	-109320	543240	245504.3	4.8559	2.840142	3.860465
Eylül 95	-85647	551928	290612.8	2.4768	6.732532	7.954506
Ekim 95	-30291	537668	325437.6	4.6614	7.980874	7.782933
Kasım 95	-153952	529474	317930.1	4.7728	6.455639	5.539004
Aralık 95	-316576	519884	201337.8	8.2915	4.230502	3.496035
Ocak 96	-67823	542583	177166.9	6.545	5.490851	7.741076
Şubat 96	-81614	534199	239423.3	5.9744	5.244606	3.908254
Mart 96	-74219	536555	269240	6.592	4.682958	4.947647
Nisan 96	-38656	532625	333624.7	6.2494	11.8433	6.913205
Mayıs 96	-378031	556251	405306.2	5.7677	5.959984	4.747242
Haziran 96	-475441	558449	455786.6	3.8459	1.583963	2.06603
Temmuz 96	-564272	559692	418709	3.7966	3.172895	1.392493
Ağustos 96	-660063	568432	442021.8	2.6659	2.854513	4.71099
Eylül 96	-750535	584808	530101.7	4.6394	6.901347	6.482406
Ekim 96	-693299	586453	637394.2	5.4865	8.055423	7.704648
Kasım 96	-744735	582345	647991	5.0772	6.676123	5.422443
Aralık 96	-1238123	575009	719389.8	6.3214	4.483816	2.36698
Ocak 97	-116026	580161	705479.4	7.2375	6.308319	5.47589
Şubat 97	-234534	574399	802153.5	6.1429	5.221838	5.87676

	Bütçe Açığı (MilyonTL)	İstihdam (Kişi)	Net Dış Varlık Girişi (MilyonTL)	Devalüasyon (%)	Enflasyon Beklentisi (%)	Enflasyon (%)
Mart 97	-411780	580701	772347.5	4.7543	4.742955	5.625093
Nisan 97	-390162	579917	803010.3	4.8414	12.6857	7.74638
Mayıs 97	-521501	606170	838355.6	4.7292	5.968285	4.181241
Haziran 97	-681709	613131	916735.6	5.0937	1.661679	2.260092
Temmuz 97	-674179	621055	1134777.5	6.327	2.00976	5.125053
Ağustos 97	-712941	630454	1357211.1	6.6499	3.534658	5.788933
Eylül 97	-768371	642449	1683208.3	4.1441	7.19834	7.732764
Ekim 97	-594302	626316	2024977.5	4.5569	8.326534	9.658146
Kasım 97	-578282	618863	1930084.3	5.1238	6.352175	6.877112
Aralık 97	-2180847	611720	1857071.2	6.6882	4.066489	4.775784
Ocak 98	-317176	610922	2061032.1	6.0739	6.663966	6.742042
Şubat 98	-567243	604651	2117671.2	5.4726	5.177468	4.724327
Mart 98	-961332	601702	2491760.6	5.4334	4.891192	3.974028
Nisan 98	-1338346	614582	3069476.1	4.3048	7.032751	5.345944
Mayıs 98	-1470522	627041	3882765.2	2.6162	4.044585	3.19243
Haziran 98	-1885730	633722	4329849.8	3.4801	2.110713	1.235166
Temmuz 98	-2198474	629928	4255208.5	2.9113	3.142374	3.227554
Ağustos 98	-2641628	632166	3920900.3	2.1034	4.786796	3.805661
Eylül 98	-3032870	641073	3052910.7	0.501	7.389892	7.080663
Ekim 98	-3010866	616515	3023284.4	1.2109	8.381909	6.429284
Kasım 98	-3078454	605850	2902926.1	5.6091	5.946186	4.475809
Aralık 98	-3697824	591945	2892329.4	4.3024	3.546266	3.219328

EK B – MATLAB Yazılım Çıktısı (Tahmin Süreci İçin)

p =

Columns 1 through 7

0.1600	0.3874	0.3840	0.8954	0.9000	0.7834	0.2939
0.1000	0.1070	0.1149	0.1466	0.1512	0.1453	0.1433
0.9000	0.8475	0.8125	0.7607	0.7345	0.7271	0.6674
0.9000	0.7142	0.6473	0.6469	0.6415	0.6407	0.6188
0.1000	0.1014	0.1107	0.1067	0.1106	0.1077	0.1081
0.7316	0.4275	0.3807	0.1702	0.1000	0.1234	0.1702
0.1000	0.1019	0.1039	0.1061	0.1084	0.1108	0.1135
0.8979	0.8947	0.8877	0.8868	0.8882	0.8899	0.8868
0.3063	0.2478	0.2037	0.1715	0.2401	0.1831	0.1523
0.1170	0.1137	0.1104	0.1016	0.1000	0.1038	0.1069
0.2843	0.3955	0.3894	0.9000	0.2478	0.1000	0.1525
0.4636	0.3495	0.3398	0.3554	0.2262	0.1443	0.1944

Columns 8 through 14

0.1577	0.1554	0.1000	0.2385	0.2709	0.3828	0.3874
0.1452	0.1514	0.1540	0.1578	0.1610	0.1685	0.1709
0.6174	0.5658	0.5316	0.5266	0.5175	0.4771	0.4519
0.6160	0.6153	0.6126	0.6082	0.6023	0.5892	0.5855
0.1082	0.1137	0.1202	0.1237	0.1298	0.1330	0.1393
0.2591	0.5304	0.4088	0.3526	0.4415	0.3480	0.2637
0.1163	0.1193	0.1226	0.1260	0.1297	0.1323	0.1350
0.8862	0.8841	0.8827	0.8871	0.8659	0.9000	0.8910
0.1762	0.2446	0.2081	0.1581	0.1043	0.1216	0.1000
0.1117	0.1113	0.1118	0.1106	0.1144	0.1175	0.1277
0.2099	0.2722	0.2177	0.2317	0.2216	0.2754	0.2089
0.2607	0.4547	0.4976	0.3962	0.2662	0.4534	0.3627

Columns 15 through 21

0.2870	0.2293	0.2224	0.2224	0.1762	0.1727	0.1762
0.1730	0.1745	0.1765	0.1769	0.1804	0.1863	0.1894
0.4502	0.4181	0.3968	0.3850	0.3640	0.3497	0.3393
0.5829	0.5829	0.5814	0.5740	0.5736	0.5715	0.5636
0.1475	0.1479	0.1560	0.1499	0.1546	0.1556	0.1642
0.4322	0.5398	0.5585	0.6661	0.7269	0.6614	0.8064
0.1378	0.1408	0.1439	0.1471	0.1504	0.1540	0.1577
0.8872	0.8711	0.8739	0.8744	0.8765	0.8752	0.8803
0.1132	0.1892	0.3012	0.3339	0.3093	0.3547	0.4025
0.1315	0.1343	0.1396	0.1437	0.1474	0.1601	0.1682
0.2048	0.1979	0.2042	0.1848	0.2190	0.2433	0.2129
0.3580	0.7621	0.3746	0.0985	0.2037	0.2170	0.4787

Columns 22 through 28

0.1797	0.2812	0.3470	0.3655	0.3574	0.3332	0.2986
0.1956	0.2021	0.2140	0.2242	0.2341	0.2457	0.2574
0.3235	0.3117	0.2999	0.2909	0.2706	0.2586	0.2494
0.5621	0.5554	0.5540	0.5537	0.5497	0.5496	0.5478
0.1707	0.1803	0.1899	0.1926	0.2090	0.2118	0.2323
0.6193	0.5725	0.7035	0.5912	0.5164	0.4368	0.4743
0.1615	0.1655	0.1697	0.1767	0.1843	0.1923	0.2010
0.8923	0.8655	0.8304	0.8842	0.8812	0.8828	0.8905
0.3241	0.2791	0.2264	0.3511	0.3050	0.3180	0.2964

0.1745	0.1732	0.1521	0.1477	0.1590	0.1644	0.1760
0.2409	0.2423	0.2873	0.2649	0.2576	0.2655	0.2612
0.5626	0.4600	0.3105	0.3952	0.3786	0.3409	0.8222

Columns 29 through 35

0.2951	0.2916	0.2974	0.2986	0.2974	0.2962	0.2974
0.2688	0.2769	0.2852	0.2913	0.3021	0.3155	0.3285
0.2396	0.2225	0.2170	0.2066	0.2033	0.1868	0.1854
0.5460	0.5451	0.5441	0.5419	0.5391	0.5374	0.5350
0.2309	0.2309	0.2433	0.2638	0.2761	0.2843	0.2884
0.6942	0.6708	0.5912	0.5585	0.5678	0.6474	0.4509
0.2103	0.2202	0.2309	0.2424	0.2546	0.2678	0.2819
0.8171	0.7961	0.7769	0.7562	0.7367	0.7490	0.7379
0.4262	0.4383	0.4451	0.4932	0.5832	0.5922	0.5697
0.1890	0.1981	0.1914	0.1957	0.2116	0.2310	0.2330
0.2550	0.2304	0.2298	0.2153	0.2406	0.2514	0.2462
0.4267	0.1325	0.2394	0.2180	0.4900	0.5676	0.4749

Columns 36 through 42

0.2986	0.2697	0.2628	0.2616	0.2628	0.2651	0.2720
0.3456	0.3664	0.3853	0.4008	0.4174	0.4344	0.4535
0.1761	0.1740	0.1683	0.1632	0.1632	0.1620	0.1616
0.5321	0.5291	0.5289	0.5244	0.5228	0.5223	0.5181
0.2966	0.3199	0.3472	0.3554	0.3951	0.3938	0.4020
0.5772	0.5164	0.4649	0.6287	0.4789	0.7129	0.6380
0.2971	0.3104	0.3245	0.3394	0.3552	0.3719	0.3896
0.6313	0.8737	0.8481	0.8099	0.8145	0.7862	0.7515
0.5293	0.5577	0.5260	0.5606	0.5563	0.7006	0.7389
0.2459	0.2434	0.2609	0.2555	0.2611	0.2675	0.2817
0.2621	0.2738	0.2598	0.2420	0.2432	0.2417	0.2464
0.3275	0.4501	0.3771	0.3449	0.8789	0.4273	0.1378

Columns 43 through 48

0.2928	0.3320	0.3274	0.3320	0.3355	0.3390
0.4785	0.5064	0.5250	0.5463	0.5713	0.6056
0.1505	0.1475	0.1417	0.1360	0.1305	0.1260
0.5148	0.5135	0.5068	0.4994	0.4955	0.4933
0.4170	0.4676	0.4882	0.5196	0.5169	0.5265
0.6287	0.7035	0.9000	0.5819	0.7784	0.5351
0.4084	0.4283	0.4494	0.4717	0.4953	0.5204
0.7532	0.7448	0.7328	0.7704	0.7739	0.4277
0.7824	0.8341	0.9000	0.8113	0.7704	0.7311
0.3212	0.3615	0.4205	0.4824	0.4652	0.4520
0.2622	0.2663	0.2342	0.2395	0.2468	0.2668
0.1612	0.2637	0.5100	0.5858	0.4531	0.2994

» t=[0.2165 0.2696 0.2421 0.9000 0.4005 0.1004 0.1275 0.1376 0.3077 0.3852
 0.3388 0.2805 0.2950 0.2609 0.2063 0.2839 0.1765 0.1367 0.1667 0.1983
 0.3342 0.3285 0.2540 0.1862 0.3271 0.1999 0.2344 0.2996 0.2277 0.1387
 0.1163 0.2265 0.2853 0.3259 0.2501 0.1487 0.2519 0.2652 0.2568 0.3273
 0.2089 0.1451 0.2403 0.2623 0.3268 0.3907 0.2984 0.2287]

t =

Columns 1 through 7

0.2165	0.2696	0.2421	0.9000	0.4005	0.1004	0.1275
--------	--------	--------	--------	--------	--------	--------

Columns 8 through 14

0.1376	0.3077	0.3852	0.3388	0.2805	0.2950	0.2609
--------	--------	--------	--------	--------	--------	--------

Columns 15 through 21

0.2063	0.2839	0.1765	0.1367	0.1667	0.1983	0.3342
--------	--------	--------	--------	--------	--------	--------

Columns 22 through 28

0.3285	0.2540	0.1862	0.3271	0.1999	0.2344	0.2996
--------	--------	--------	--------	--------	--------	--------

Columns 29 through 35

```

0.2277 0.1387 0.1163 0.2265 0.2853 0.3259 0.2501
Columns 36 through 42
0.1487 0.2519 0.2652 0.2568 0.3273 0.2089 0.1451
Columns 43 through 48
0.2403 0.2623 0.3268 0.3907 0.2984 0.2287

```

s1=4;

```
» [w1,b1,w2,b2]=initff(p.s1,'tansig',t,'tansig');
```

```
» df=250;
```

```
» me=1000;
```

```
» eg=0.005;
```

```
» lr=0.01;
```

```
» tp=[df me eg lr];
```

```
» [w1,b1,w2,b2]=trainbpx(w1,b1,'tansig',w2,b2,'tansig',p,t,tp)
```

TRAINBPX: 0/1000 epochs. lr = 0.01, SSE = 17.2246.

TRAINBPX: 250/1000 epochs. lr = 0.0122984, SSE = 0.239756.

TRAINBPX: 500/1000 epochs. lr = 0.0486166, SSE = 0.145632.

TRAINBPX: 750/1000 epochs. lr = 0.201794, SSE = 0.120002.

TRAINBPX: 1000/1000 epochs. lr = 0.0127388, SSE = 0.112856.

TRAINBPX: Network error did not reach the error goal.

Further training may be necessary, or try different
initial weights and biases and/or more hidden neurons.

w1 =

Columns 1 through 7

```

-0.8166 -0.2235 0.1934 -1.0313 0.6104 1.0159 0.9049
0.1945 -0.4750 -0.2525 1.7197 -1.6040 -0.4406 -0.9498
0.7992 -0.2018 0.2110 -1.3117 -1.7535 -0.3200 0.8729
-0.6644 1.1206 -0.5352 0.5316 0.9420 0.3200 0.6969

```

Columns 8 through 12

```

2.0034 0.7451 -0.6297 -1.1161 0.6028
-1.4733 -0.0593 1.7143 -0.4545 -0.8170
-1.4441 -0.5148 1.2115 -0.7968 -0.7610
0.9056 -0.9729 -0.7741 0.1568 -1.1514

```

b1 =

```

-0.2440
-0.0436
1.7249
-1.5954

```

w2 =

```
-0.9770 -0.8965 -0.3006 -0.2461
```

b2 =

```
-0.0071
```

```
» z=simuff(ap,w1,b1,'tansig',w2,b2,'tansig')
```

z =

Columns 1 through 7

```
0.2851 0.2323 0.2037 0.2553 0.1111 -0.0351 0.0181
```

Columns 8 through 12

```

0.0895 0.1870 0.2071 0.1218 0.0275

» ee=at-z

ee =
Columns 1 through 7
0.0088 -0.0054 -0.0017 -0.0077 0.0650 0.1462 0.1592
Columns 8 through 12
0.1070 0.1182 0.0764 0.0969 0.1495

» sumsqr(ee)

ans =
0.1141

» [w1,b1,w2,b2]=trainbpx(w1,b1,'tansig',w2,b2,'tansig',p,t,tp)

TRAINBPX: 0/1000 epochs. lr = 0.01, SSE = 0.112856.
TRAINBPX: 250/1000 epochs. lr = 0.0104291, SSE = 0.102843.
TRAINBPX: 500/1000 epochs. lr = 0.0140934, SSE = 0.0981857.
TRAINBPX: 750/1000 epochs. lr = 0.0220472, SSE = 0.0950416.
TRAINBPX: 1000/1000 epochs. lr = 0.0344899, SSE = 0.0925813.

TRAINBPX: Network error did not reach the error goal.
Further training may be necessary, or try different
initial weights and biases and/or more hidden neurons.

w1 =
Columns 1 through 7
-1.0257 -0.2575 0.2253 -0.9839 0.6187 1.2381 0.8988
0.3697 -0.4900 -0.2335 1.7108 -1.5876 -0.5227 -0.9486
0.8541 -0.2778 0.1607 -1.3292 -1.8080 -0.3475 0.8109
-0.5790 1.1056 -0.6596 0.5062 0.9331 0.2917 0.6805
Columns 8 through 12
2.0840 0.8584 -0.6470 -1.1840 0.6138
-1.5381 0.0530 1.6713 -0.4018 -0.9496
-1.4593 -0.5353 1.1026 -0.7687 -0.8063
0.8865 -0.9541 -0.8587 0.1964 -1.1716

b1 =
-0.1699
-0.0651
1.6944
-1.6087

w2 =
-1.1267 -0.9581 -0.2707 -0.2943

b2 =
0.0378

» z=simuff(ap,w1,b1,'tansig',w2,b2,'tansig')

z =
Columns 1 through 7
0.2782 0.2303 0.2103 0.2701 0.1576 0.0136 0.0778
Columns 8 through 12
0.1436 0.2317 0.2509 0.1769 0.0861

```

```

» ee=at-z

ee =
Columns 1 through 7
    0.0157 -0.0034 -0.0083 -0.0225    0.0185    0.0975    0.0995
Columns 8 through 12
    0.0529    0.0735    0.0326    0.0418    0.0909

» sumsqr(ee)

ans =
    0.0399
...
...

» [w1.b1.w2.b2]=trainbpx(w1.b1.'tansig'.w2.b2.'tansig'.p.t.tp)

TRAINBPX: 0/100 epochs. lr = 0.01, SSE = 0.0819094.
TRAINBPX: 25/100 epochs. lr = 0.0338635, SSE = 0.0818839.
TRAINBPX: 50/100 epochs. lr = 0.114674, SSE = 0.0818042.
TRAINBPX: 75/100 epochs. lr = 0.156544, SSE = 0.0819437.
TRAINBPX: 100/100 epochs. lr = 0.00888881, SSE = 0.0835264.

TRAINBPX: Network error did not reach the error goal.
Further training may be necessary, or try different
initial weights and biases and/or more hidden neurons.

w1 =
Columns 1 through 7
    -1.2930   -0.3075    0.2289   -0.9674    0.6212    1.4656    0.8831
     0.5731   -0.5516   -0.1751    1.7362   -1.5996   -0.6487   -0.9791
     0.9344   -0.3593    0.0497   -1.3631   -1.8645   -0.3741    0.7431
    -0.4354    1.0590   -0.9346    0.4795    0.8988    0.3146    0.6315
Columns 8 through 12
     2.1474    0.9793   -0.6695   -1.1580    0.6591
    -1.6198    0.1920    1.5752   -0.3182   -1.0813
    -1.4907   -0.5503    0.9796   -0.7285   -0.7847
     0.8839   -0.9627   -1.0561    0.2753   -1.0609

b1 =
    -0.1074
    -0.0509
     1.6699
    -1.5833

w2 =
    -1.2534   -1.0198   -0.2498   -0.3818

b2 =
     0.0332

» z=simuff(ap.w1.b1.'tansig'.w2.b2.'tansig')

z =
Columns 1 through 7
     0.2725    0.2269    0.2151    0.2857    0.2096    0.0951    0.1573
Columns 8 through 12
     0.2081    0.2703    0.2842    0.2234    0.1658

```

```
» ee=at-z
```

```
ee =
```

```
Columns 1 through 7
```

```
0.0214 0.0000 -0.0131 -0.0381 -0.0335 0.0160 0.0200
```

```
Columns 8 through 12
```

```
-0.0116 0.0349 -0.0007 -0.0047 0.0112
```

```
» sumsqr(ee)
```

```
ans =
```

```
0.0054
```



EK C

Tablo C.1 Gelecek Görüntülerinin Listesi

Senaryo No	Ücretler	Bütçe Açığı	Devalüasyon	Enflasyon
1	670.45	-5354481.2	2.31	5.70
2	724.95	-6437548.9	3.02	3.90
3	662.64	-3132412.7	5.58	4.94
4	698.36	-3729866.1	3.57	6.71
5	691.83	-3452603.3	3.11	3.63
6	666.23	-4830069.5	5.99	5.45
7	696.56	-5566819.6	5.73	7.29
8	675.98	-6410048.1	2.00	7.87
9	622.29	-3308210.6	2.58	3.82
10	712.49	-4240838.3	-0.06	7.30
11	627.74	-4786542.5	2.47	2.87
12	703.18	-2057584.2	5.20	5.26
13	650.48	-3763451.6	5.05	4.83
14	632.81	-5943256.3	2.10	8.91
15	612.48	-5339631.6	4.50	5.98
16	686.02	-4625080.2	3.24	5.09
17	680.58	-5401274.2	6.98	4.36
18	637.18	-6019519.0	4.68	7.37
19	612.49	-4514960.9	7.94	2.35
20	629.55	-4167412.2	2.59	4.67
21	609.92	-4393931.7	5.14	7.03
22	713.46	-4120698.8	1.33	5.83
23	589.94	-1843045.6	2.88	6.20
24	678.90	-5171858.6	0.64	0.73
25	604.87	-3094940.9	6.91	4.19
26	672.65	-3526077.0	3.00	5.80
27	676.16	-5422121.7	2.29	5.94
28	624.67	-3696664.2	5.93	4.23
29	676.48	-4845303.3	4.48	4.15
30	683.00	-4440488.1	3.24	3.03
31	668.84	-6165418.3	2.32	2.86
32	553.59	-3039994.9	4.51	5.89
33	630.76	-4055994.8	4.92	3.47
34	639.01	-4126483.6	3.52	6.56
35	682.26	-4646905.2	3.68	5.95
36	677.03	-3766473.1	2.75	2.64
37	689.24	-3729715.7	6.21	8.56
38	610.38	-3233257.3	4.93	4.52
39	704.16	-5554104.1	5.23	6.31
40	652.84	-2220324.0	3.07	6.20
41	696.60	-3208911.6	1.71	7.18
42	583.67	-4971323.0	6.29	4.08
43	610.72	-6399600.6	1.07	8.97
44	562.90	-769964.1	3.11	5.28

Senaryo No	Ücretler	Bütçe Açığı	Devalüasyon	Enflasyon
45	647.02	-4483211.9	3.33	5.91
46	622.76	-7477996.7	2.83	5.61
47	569.68	-6142332.7	4.56	6.30
48	645.45	-4071531.8	3.39	4.89
49	633.51	-1291032.1	0.00	4.14
50	729.46	-7353141.0	4.37	7.72
51	610.40	-3490474.5	3.33	3.38
52	681.42	-3359237.8	0.85	5.90
53	632.76	-6322463.0	6.48	3.46
54	634.61	-5269321.1	5.38	5.80
55	705.29	-6267468.5	4.46	6.36
56	646.32	-8826622.1	5.10	7.28
57	729.46	-4536300.9	4.11	9.14
58	615.50	-4701280.5	3.19	4.84
59	638.59	-1478063.6	2.13	0.15
60	712.34	-6533615.3	-0.85	4.20
61	737.75	-4263449.7	4.84	2.55
62	681.59	-4853406.0	3.58	3.63
63	660.22	-4019515.1	2.94	6.75
64	629.25	-5531906.7	3.19	4.21
65	646.46	-4504480.5	2.51	4.51
66	692.83	-5791599.5	5.24	9.33
67	740.80	-5926147.6	1.66	2.74
68	626.99	-4180775.6	0.58	6.88
69	598.88	-4448424.4	3.16	4.27
70	679.67	-5224593.2	2.89	8.97
71	622.65	-5190876.0	1.98	1.66
72	663.06	-4622821.0	4.27	7.49
73	630.98	-4939840.4	3.92	3.23
74	661.65	-4964264.2	2.92	6.82
75	698.44	-4821630.5	3.60	2.30
76	673.07	-3467899.2	4.05	7.22
77	643.56	-7539985.2	6.06	4.93
78	679.87	-3430700.6	1.82	3.14
79	667.04	-1390240.3	0.47	6.64
80	623.47	-3807814.5	2.16	4.38
81	608.50	-2001570.9	4.11	4.13
82	613.95	-5595625.0	3.62	3.98
83	640.61	-5751285.8	4.18	5.30
84	700.61	-6110287.0	2.43	7.40
85	649.67	-3367704.1	3.10	7.01
86	589.58	-2337077.3	7.83	4.70
87	681.84	-4178081.9	5.06	4.81
88	710.62	-3186241.0	3.40	4.21
89	708.37	-3980421.4	2.57	5.41
90	637.43	-4633155.4	7.07	5.21
91	660.35	-3853135.0	3.02	6.42
92	650.90	-2982880.6	5.38	3.33
93	684.09	-4851898.7	4.00	5.20
94	651.74	-2227602.2	3.48	6.20
95	605.28	-4368108.4	4.49	3.33
96	611.12	-1584757.8	2.29	6.46
97	683.13	-5901123.3	4.28	1.38
98	639.37	-4958221.9	1.42	0.97
99	577.92	-4812578.0	6.38	5.10
100	562.30	-3918004.7	4.91	3.12

EK D – MATLAB Yazılım Çıktısı (Kümeleme Çalışması İçin / 100 veri – 10 grup)

```

» p=[0.40      1.71      0.21      1.07      0.91      0.30      1.03      0.53      -0.75      1.41      -0.62
      1.18      -0.08      -0.50      -0.99      0.77      0.64      -0.39      -0.99      -0.58      -1.05      1.43
      -1.52      0.60      -1.17      0.45      0.54      -0.69      0.55      0.70      0.36      -2.39      -0.55
      -0.35      0.68      0.56      0.85      -1.04      1.21      -0.02      1.03      -1.68      -1.03      -2.17
      -0.16      -0.74      -2.01      -0.20      -0.48      1.81      -1.04      0.66      -0.50      -0.46      1.24
      -0.18      1.81      -0.91      -0.36      1.40      2.01      0.67      0.16      -0.58      -0.17      0.94
      2.09      -0.64      -1.31      0.62      -0.74      0.22      -0.54      0.19      1.07      0.46      -0.24
      0.63      0.32      -0.72      -1.08      -0.95      -0.31      1.12      -0.10      -1.53      0.67      1.36
      1.31      -0.39      0.16      -0.07      0.73      -0.05      -1.16      -1.02      0.71      -0.34      -1.81
      -2.19;
-0.62      -1.36      0.90      0.49      0.68      -0.26      -0.77      -1.34      0.78      0.14      -0.23      1.63
      0.47      -1.02      -0.61      -0.12      -0.65      -1.08      -0.05      0.19      0.04      0.22      1.78
      -0.50      0.92      0.63      -0.67      0.51      -0.27      0.00      -1.18      0.96      0.27      0.22
      -0.14      0.47      0.49      0.83      -0.76      1.52      0.85      -0.36      -1.34      2.52      -0.03
      -2.07      -1.16      0.26      2.16      -1.99      0.65      0.74      -1.28      -0.56      -1.25      -3.00
      -0.06      -0.17      2.03      -1.43      0.13      -0.28      0.29      -0.74      -0.04      -0.92      -1.01
      0.18      0.00      -0.53      -0.51      -0.12      -0.34      -0.35      -0.26      0.67      -2.12      0.69
      2.09      0.44      1.67      -0.79      -0.89      -1.14      0.74      1.44      0.18      0.86      0.32
      -0.13      0.41      1.00      -0.28      1.52      0.05      1.96      -1.00      -0.35      -0.25      0.36;
-0.77      -0.36      1.10      -0.05      -0.31      1.33      1.18      -0.94      -0.61      -2.11      -0.67      0.88
      0.80      -0.88      0.48      -0.23      1.90      0.58      2.44      -0.61      0.85      -1.32      -0.44
      -1.72      1.86      -0.37      -0.78      1.30      0.47      -0.23      -0.76      0.49      0.72      -0.08
      0.01      -0.51      1.46      0.73      0.90      -0.33      -1.11      1.50      -1.47      -0.31      -0.18
      -0.47      0.51      -0.15      -2.08      0.41      -0.18      -1.60      1.61      0.98      0.46      0.82
      0.26      -0.26      -0.87      -2.56      0.68      -0.04      -0.40      -0.26      -0.65      0.91      -1.14
      -1.75      -0.28      -0.43      -0.95      0.35      0.15      -0.42      -0.03      0.23      1.37      -1.04
      -1.81      -0.85      0.26      -0.02      0.30      -0.70      -0.31      2.38      0.80      -0.14      -0.62
      1.95      -0.36      0.98      0.20      -0.10      0.48      -0.78      0.36      -1.27      1.55      0.72;
0.29      -0.65      -0.11      0.81      -0.78      0.16      1.12      1.42      -0.69      1.12      -1.18      0.06
      -0.16      1.96      0.43      -0.03      -0.41      1.16      -1.45      -0.24      0.98      0.36      0.55
      -2.30      -0.50      0.34      0.42      -0.47      -0.52      -1.10      -1.19      0.39      -0.87      0.74
      0.42      -1.30      1.78      -0.33      0.61      0.55      1.06      -0.55      1.99      0.07      0.40
      0.24      0.60      -0.13      -0.52      1.34      -0.92      0.39      -0.88      0.34      0.63      1.11
      2.08      -0.16      -2.60      -0.49      -1.35      -0.79      0.84      -0.49      -0.33      2.18      -1.25
      0.91      -0.46      1.99      -1.81      1.22      -1.00      0.87      -1.48      1.08      -0.11      -1.04
      0.78      -0.40      -0.53      -0.61      0.08      1.18      0.97      -0.23      -0.17      -0.49      0.14
      0.03      0.67      -0.95      0.03      0.55      -0.94      0.69      -1.96      -2.17      -0.02      -
1.05]

```

p =

Columns 1 through 7

```

0.4000      1.7100      0.2100      1.0700      0.9100      0.3000      1.0300
-0.6200     -1.3600      0.9000      0.4900      0.6800     -0.2600     -0.7700
-0.7700     -0.3600      1.1000     -0.0500     -0.3100      1.3300      1.1800
0.2900     -0.6500     -0.1100      0.8100     -0.7800      0.1600      1.1200

```

Columns 8 through 14

```

0.5300     -0.7500      1.4100     -0.6200      1.1800     -0.0800     -0.5000
-1.3400      0.7800      0.1400     -0.2300      1.6300      0.4700     -1.0200
-0.9400     -0.6100     -2.1100     -0.6700      0.8800      0.8000     -0.8800
1.4200     -0.6900      1.1200     -1.1800      0.0600     -0.1600      1.9600

```

Columns 15 through 21

```

-0.9900      0.7700      0.6400     -0.3900     -0.9900     -0.5800     -1.0500
-0.6100     -0.1200     -0.6500     -1.0800     -0.0500      0.1900      0.0400
0.4800     -0.2300      1.9000      0.5800      2.4400     -0.6100      0.8500
0.4300     -0.0300     -0.4100      1.1600     -1.4500     -0.2400      0.9800

```

Columns 22 through 28

1.4300	-1.5200	0.6000	-1.1700	0.4500	0.5400	-0.6900
0.2200	1.7800	-0.5000	0.9200	0.6300	-0.6700	0.5100
-1.3200	-0.4400	-1.7200	1.8600	-0.3700	-0.7800	1.3000
0.3600	0.5500	-2.3000	-0.5000	0.3400	0.4200	-0.4700

Columns 29 through 35

0.5500	0.7000	0.3600	-2.3900	-0.5500	-0.3500	0.6800
-0.2700	0	-1.1800	0.9600	0.2700	0.2200	-0.1400
0.4700	-0.2300	-0.7600	0.4900	0.7200	-0.0800	0.0100
-0.5200	-1.1000	-1.1900	0.3900	-0.8700	0.7400	0.4200

Columns 36 through 42

0.5600	0.8500	-1.0400	1.2100	-0.0200	1.0300	-1.6800
0.4700	0.4900	0.8300	-0.7600	1.5200	0.8500	-0.3600
-0.5100	1.4600	0.7300	0.9000	-0.3300	-1.1100	1.5000
-1.3000	1.7800	-0.3300	0.6100	0.5500	1.0600	-0.5500

Columns 43 through 49

-1.0300	-2.1700	-0.1600	-0.7400	-2.0100	-0.2000	-0.4800
-1.3400	2.5200	-0.0300	-2.0700	-1.1600	0.2600	2.1600
-1.4700	-0.3100	-0.1800	-0.4700	0.5100	-0.1500	-2.0800
1.9900	0.0700	0.4000	0.2400	0.6000	-0.1300	-0.5200

Columns 50 through 56

1.8100	-1.0400	0.6600	-0.5000	-0.4600	1.2400	-0.1800
-1.9900	0.6500	0.7400	-1.2800	-0.5600	-1.2500	-3.0000
0.4100	-0.1800	-1.6000	1.6100	0.9800	0.4600	0.8200
1.3400	-0.9200	0.3900	-0.8800	0.3400	0.6300	1.1100

Columns 57 through 63

1.8100	-0.9100	-0.3600	1.4000	2.0100	0.6700	0.1600
-0.0600	-0.1700	2.0300	-1.4300	0.1300	-0.2800	0.2900
0.2600	-0.2600	-0.8700	-2.5600	0.6800	-0.0400	-0.4000
2.0800	-0.1600	-2.6000	-0.4900	-1.3500	-0.7900	0.8400

Columns 64 through 70

-0.5800	-0.1700	0.9400	2.0900	-0.6400	-1.3100	0.6200
-0.7400	-0.0400	-0.9200	-1.0100	0.1800	0	-0.5300
-0.2600	-0.6500	0.9100	-1.1400	-1.7500	-0.2800	-0.4300
-0.4900	-0.3300	2.1800	-1.2500	0.9100	-0.4600	1.9900

Columns 71 through 77

-0.7400	0.2200	-0.5400	0.1900	1.0700	0.4600	-0.2400
-0.5100	-0.1200	-0.3400	-0.3500	-0.2600	0.6700	-2.1200
-0.9500	0.3500	0.1500	-0.4200	-0.0300	0.2300	1.3700
-1.8100	1.2200	-1.0000	0.8700	-1.4800	1.0800	-0.1100

Columns 78 through 84

0.6300	0.3200	-0.7200	-1.0800	-0.9500	-0.3100	1.1200
0.6900	2.0900	0.4400	1.6700	-0.7900	-0.8900	-1.1400
-1.0400	-1.8100	-0.8500	0.2600	-0.0200	0.3000	-0.7000
-1.0400	0.7800	-0.4000	-0.5300	-0.6100	0.0800	1.1800

Columns 85 through 91

-0.1000	-1.5300	0.6700	1.3600	1.3100	-0.3900	0.1600
0.7400	1.4400	0.1800	0.8600	0.3200	-0.1300	0.4100
-0.3100	2.3800	0.8000	-0.1400	-0.6200	1.9500	-0.3600
0.9700	-0.2300	-0.1700	-0.4900	0.1400	0.0300	0.6700

Columns 92 through 98

-0.0700	0.7300	-0.0500	-1.1600	-1.0200	0.7100	-0.3400
1.0000	-0.2800	1.5200	0.0500	1.9600	-1.0000	-0.3500
0.9800	0.2000	-0.1000	0.4800	-0.7800	0.3600	-1.2700
-0.9500	0.0300	0.5500	-0.9400	0.6900	-1.9600	-2.1700

Columns 99 through 100

-1.8100	-2.1900
-0.2500	0.3600
1.5500	0.7200
-0.0200	-1.0500

```
» w=initc(p,10)
```

```
w =
```

```
-0.1500 -0.2400 -0.0600 -0.2100  
-0.1500 -0.2400 -0.0600 -0.2100  
-0.1500 -0.2400 -0.0600 -0.2100  
-0.1500 -0.2400 -0.0600 -0.2100  
-0.1500 -0.2400 -0.0600 -0.2100  
-0.1500 -0.2400 -0.0600 -0.2100  
-0.1500 -0.2400 -0.0600 -0.2100  
-0.1500 -0.2400 -0.0600 -0.2100  
-0.1500 -0.2400 -0.0600 -0.2100
```

```
» df=100;
```

```
» me=10000;
```

```
» lr=0.1;
```

```
» tp=[df me lr];
```

```
» w=trainc(w,p,tp)
```

```
TRAINC: 0/10000 epochs.
```

```
TRAINC: 100/10000 epochs.
```

```
TRAINC: 200/10000 epochs.
```

```
TRAINC: 300/10000 epochs.
```

```
TRAINC: 400/10000 epochs.
```

```
TRAINC: 500/10000 epochs.
```

```
...
```

```
TRAINC: 9500/10000 epochs.
```

```
TRAINC: 9600/10000 epochs.
```

```
TRAINC: 9700/10000 epochs.
```

```
TRAINC: 9800/10000 epochs.
```

```
TRAINC: 9900/10000 epochs.
```

```
TRAINC: 10000/10000 epochs.
```

```
w =
```

```
-0.8765 1.6600 -0.5805 -0.0262  
-0.2638 -0.1559 -0.7842 -1.5241  
1.0453 -0.1797 -0.3105 -0.8426  
-0.6772 -1.1569 0.6102 0.1481  
-1.3815 0.1308 1.6836 -0.6488  
0.5029 0.5781 0.9018 -0.3010  
-0.8695 0.0070 0.0060 -0.4442  
0.4314 -0.4931 -0.9846 0.9140  
0.8523 -0.4559 0.6097 1.3887  
0.5319 0.5667 -0.3449 0.7360
```

```
» a=simuc(p,w)
```

```
a =
```

```
(8.1) 1  
(3.2) 1  
(6.3) 1  
(10.4) 1  
(3.5) 1  
(6.6) 1  
(9.7) 1
```

(8.8) 1
(7.9) 1
(8.10) 1
(2.11) 1
(6.12) 1
(6.13) 1
(8.14) 1
(4.15) 1
(3.16) 1
(6.17) 1
(4.18) 1
(5.19) 1
(7.20) 1
(4.21) 1
(8.22) 1
(1.23) 1
(2.24) 1
(5.25) 1
(10.26) 1
(8.27) 1
(5.28) 1
(6.29) 1
(3.30) 1
(2.31) 1
(1.32) 1
(7.33) 1
(10.34) 1
(10.35) 1
(3.36) 1
(9.37) 1
(7.38) 1
(9.39) 1
(1.40) 1
(10.41) 1
(5.42) 1
(8.43) 1
(1.44) 1
(10.45) 1
(4.46) 1
(4.47) 1
(7.48) 1
(1.49) 1
(9.50) 1
(7.51) 1
(10.52) 1
(4.53) 1
(4.54) 1
(9.55) 1
(4.56) 1
(9.57) 1
(7.58) 1
(2.59) 1
(8.60) 1
(3.61) 1
(3.62) 1
(10.63) 1
(7.64) 1
(7.65) 1
(9.66) 1
(3.67) 1

(8.68)	1
(7.69)	1
(9.70)	1
(2.71)	1
(9.72)	1
(7.73)	1
(8.74)	1
(3.75)	1
(10.76)	1
(4.77)	1
(3.78)	1
(1.79)	1
(7.80)	1
(1.81)	1
(7.82)	1
(4.83)	1
(8.84)	1
(10.85)	1
(5.86)	1
(6.87)	1
(3.88)	1
(10.89)	1
(5.90)	1
(10.91)	1
(6.92)	1
(3.93)	1
(1.94)	1
(7.95)	1
(1.96)	1
(3.97)	1
(2.98)	1
(5.99)	1
(5.100)	1

EK E

Tablo E.1 Kümeleme ve Korelasyon Analizleri Sonuçları

Kümeler	Senaryolar	Ücretler	Bütçe Açığı	Develüasyon	Enflasyon Beklentisi	Korelasyon sonuçları
1	23	589.94	-1843045.6	2.88	6.20	İyi
	32	553.59	-3039994.9	4.51	5.89	
	40	652.84	-2220324.0	3.07	6.20	
	44	562.90	-769964.1	3.11	5.28	
	49	633.51	-1291032.1	0.00	4.14	
	79	667.04	-1390240.3	0.47	6.64	
	81	608.50	-2001570.9	4.11	4.13	
	94	651.74	-2227602.2	3.48	6.20	
	96	611.12	-1584757.8	2.29	6.46	
2	11	627.74	-4786542.5	2.47	2.87	Çok iyi
	24	678.90	-5171858.6	0.64	0.73	
	31	668.84	-6165418.3	2.32	2.86	
	59	638.59	-1478063.6	2.13	0.15	
	71	622.65	-5190876.0	1.98	1.66	
	98	639.37	-4958221.9	1.42	0.97	
3	2	724.95	-6437548.9	3.02	3.90	Kötü
	5	691.83	-3452603.3	3.11	3.63	
	16	686.02	-4625080.2	3.24	5.09	
	30	683.00	-4440488.1	3.24	3.03	
	36	677.03	-3766473.1	2.75	2.64	
	61	737.75	-4263449.7	4.84	2.55	
	62	681.59	-4853406.0	3.58	3.63	
	67	740.80	-5926147.6	1.66	2.74	
	75	698.44	-4821630.5	3.60	2.30	
	78	679.87	-3430700.6	1.82	3.14	
	88	710.62	-3186241.0	3.40	4.21	
	93	684.09	-4851898.7	4.00	5.20	
	97	683.13	-5901123.3	4.28	1.38	
4	15	612.48	-5339631.6	4.50	5.98	Kötü
	18	637.18	-6019519.0	4.68	7.37	
	21	609.92	-4393931.7	5.14	7.03	
	46	622.76	-7477996.7	2.83	5.61	
	47	569.68	-6142332.7	4.56	6.30	
	53	632.76	-6322463.0	6.48	3.46	
	54	634.61	-5269321.1	5.38	5.80	
	56	646.32	-8826622.1	5.10	7.28	
	77	643.56	-7539985.2	6.06	4.93	
5	83	640.61	-5751285.8	4.18	5.30	İyi
	19	612.49	-4514960.9	7.94	2.35	
	25	604.87	-3094940.9	6.91	4.19	
	28	624.67	-3696664.2	5.93	4.23	
	42	583.67	-4971323.0	6.29	4.08	
	86	589.58	-2337077.3	7.83	4.70	
	90	637.43	-4633155.4	7.07	5.21	
99	577.92	-4812578.0	6.38	5.10		

Kümeler	Senaryolar	Ücretler	Bütçe Açığı	Develüasyon	Enflasyon Beklentisi	Korelasyon sonuçları
	100	562.30	-3918004.7	4.91	3.12	
6	3	662.64	-3132412.7	5.58	4.94	İyi
	6	666.23	-4830069.5	5.99	5.45	
	12	703.18	-2057584.2	5.20	5.26	
	13	650.48	-3763451.6	5.05	4.83	
	17	680.58	-5401274.2	6.98	4.36	
	29	676.48	-4845303.3	4.48	4.15	
	87	681.84	-4178081.9	5.06	4.81	
	92	650.90	-2982880.6	5.38	3.33	
7	9	622.29	-3308210.6	2.58	3.82	Kötü
	20	629.55	-4167412.2	2.59	4.67	
	33	630.76	-4055994.8	4.92	3.47	
	38	610.38	-3233257.3	4.93	4.52	
	48	645.45	-4071531.8	3.39	4.89	
	51	610.40	-3490474.5	3.33	3.38	
	58	615.50	-4701280.5	3.19	4.84	
	64	629.25	-5531906.7	3.19	4.21	
	65	646.46	-4504480.5	2.51	4.51	
	69	598.88	-4448424.4	3.16	4.27	
	73	630.98	-4939840.4	3.92	3.23	
	80	623.47	-3807814.5	2.16	4.38	
	82	613.95	-5595625.0	3.62	3.98	
	95	605.28	-4368108.4	4.49	3.33	
8	1	670.45	-5354481.2	2.31	5.70	Çok iyi
	8	675.98	-6410048.1	2.00	7.87	
	10	712.49	-4240838.3	-0.06	7.30	
	14	632.81	-5943256.3	2.10	8.91	
	22	713.46	-4120698.8	1.33	5.83	
	27	676.16	-5422121.7	2.29	5.94	
	43	610.72	-6399600.6	1.07	8.97	
	60	712.34	-6533615.3	-0.85	4.20	
	68	626.99	-4180775.6	0.58	6.88	
	74	661.65	-4964264.2	2.92	6.82	
9	84	700.61	-6110287.0	2.43	7.40	Kötü
	7	696.56	-5566819.6	5.73	7.29	
	37	689.24	-3729715.7	6.21	8.56	
	39	704.16	-5554104.1	5.23	6.31	
	50	729.46	-7353141.0	4.37	7.72	
	55	705.29	-6267468.5	4.46	6.36	
	57	729.46	-4536300.9	4.11	9.14	
	66	692.83	-5791599.5	5.24	9.33	
10	70	679.67	-5224593.2	2.89	8.97	İyi
	72	663.06	-4622821.0	4.27	7.49	
	4	698.36	-3729866.1	3.57	6.71	
	26	672.65	-3526077.0	3.00	5.80	
	34	639.01	-4126483.6	3.52	6.56	
	35	682.26	-4646905.2	3.68	5.95	
	41	696.60	-3208911.6	1.71	7.18	
	45	647.02	-4483211.9	3.33	5.91	
	52	681.42	-3359237.8	0.85	5.90	
	63	660.22	-4019515.1	2.94	6.75	
	76	673.07	-3467899.2	4.05	7.22	
	85	649.67	-3367704.1	3.10	7.01	
	89	708.37	-3980421.4	2.57	5.41	
	91	660.35	-3853135.0	3.02	6.42	

EK F – MATLAB Yazılım Çıktısı (Kümeleme Çalışması İçin / 54 veri – 27 grup)

```
» load cluster
» w=inite(p,27)
```

```
w =
```

```
-0.3749  0.1995  0.0721 -0.3582
-0.3749  0.1995  0.0721 -0.3582
-0.3749  0.1995  0.0721 -0.3582
-0.3749  0.1995  0.0721 -0.3582
-0.3749  0.1995  0.0721 -0.3582
-0.3749  0.1995  0.0721 -0.3582
-0.3749  0.1995  0.0721 -0.3582
-0.3749  0.1995  0.0721 -0.3582
-0.3749  0.1995  0.0721 -0.3582
-0.3749  0.1995  0.0721 -0.3582
-0.3749  0.1995  0.0721 -0.3582
-0.3749  0.1995  0.0721 -0.3582
-0.3749  0.1995  0.0721 -0.3582
-0.3749  0.1995  0.0721 -0.3582
-0.3749  0.1995  0.0721 -0.3582
-0.3749  0.1995  0.0721 -0.3582
-0.3749  0.1995  0.0721 -0.3582
-0.3749  0.1995  0.0721 -0.3582
-0.3749  0.1995  0.0721 -0.3582
-0.3749  0.1995  0.0721 -0.3582
-0.3749  0.1995  0.0721 -0.3582
-0.3749  0.1995  0.0721 -0.3582
-0.3749  0.1995  0.0721 -0.3582
-0.3749  0.1995  0.0721 -0.3582
-0.3749  0.1995  0.0721 -0.3582
-0.3749  0.1995  0.0721 -0.3582
-0.3749  0.1995  0.0721 -0.3582
-0.3749  0.1995  0.0721 -0.3582
-0.3749  0.1995  0.0721 -0.3582
```

```
» df=1000;
```

```
» me=50000;
```

```
» lr=0.1;
```

```
» tp=[df me lr];
```

```
» w=trainc(w,p,tp)
```

```
TRAINC: 0/50000 epochs.
```

```
TRAINC: 1000/50000 epochs.
```

```
TRAINC: 2000/50000 epochs.
```

```
TRAINC: 3000/50000 epochs.
```

```
TRAINC: 4000/50000 epochs.
```

```
TRAINC: 5000/50000 epochs.
```

```
...
```

```
TRAINC: 45000/50000 epochs.
```

TRAINC: 46000/50000 epochs.
 TRAINC: 47000/50000 epochs.
 TRAINC: 48000/50000 epochs.
 TRAINC: 49000/50000 epochs.
 TRAINC: 50000/50000 epochs.

w =

-1.3809	-0.0061	1.2912	-0.6802
0.4576	-1.0783	-0.9141	-1.6179
-0.1433	0.8552	-0.4258	0.4638
0.4858	-0.8305	-0.2517	0.5238
-1.3211	0.2784	1.5103	-0.3724
-1.5659	0.3712	0.9050	-0.5048
0.3758	0.0762	0.1187	0.3033
0.4658	0.0876	-0.3742	0.6343
0.0880	1.2307	-0.6005	0.3655
-1.1386	0.0193	1.2412	-0.7431
1.0407	0.1909	-0.4177	0.5362
0.3690	-0.4833	1.1556	-0.2566
0.1084	-0.2606	-0.2613	0.6774
-0.2000	0.5666	-0.6722	-2.2831
0.2116	-0.7865	-0.4437	0.8133
-0.2925	-1.5137	-0.7784	1.7089
0.3309	1.0695	-0.6408	0.5805
-1.6177	1.6639	0.2178	0.0358
0.3941	-0.7853	-0.9222	-1.7209
0.6801	0.4973	-0.3766	0.4876
-1.0911	1.3370	-0.3084	0.2598
0.9822	0.2258	-0.6307	0.1834
1.3185	-0.6030	-1.1204	0.2266
0.7889	-0.6082	-0.1488	0.4749
0.3492	0.3747	0.6984	0.0871
0.3079	-0.2625	0.0750	0.3970
0.1223	-0.0927	1.0269	-0.3101

» a=simuc(p,w)

a =

(21.1)	1
(6.2)	1
(9.3)	1
(18.4)	1
(9.5)	1
(17.6)	1
(18.7)	1
(3.8)	1
(21.9)	1
(19.10)	1
(19.11)	1
(2.12)	1
(14.13)	1
(19.14)	1
(19.15)	1
(10.16)	1
(5.17)	1
(10.18)	1
(1.19)	1
(5.20)	1

(12.21)	1
(1.22)	1
(6.23)	1
(25.24)	1
(12.25)	1
(25.26)	1
(27.27)	1
(12.28)	1
(12.29)	1
(12.30)	1
(27.31)	1
(4.32)	1
(16.33)	1
(23.34)	1
(16.35)	1
(23.36)	1
(4.37)	1
(16.38)	1
(23.39)	1
(13.40)	1
(15.41)	1
(4.42)	1
(11.43)	1
(20.44)	1
(13.45)	1
(24.46)	1
(11.47)	1
(26.48)	1
(22.49)	1
(13.50)	1
(7.51)	1
(8.52)	1
(22.53)	1
(8.54)	1

EK G – MATLAB Yazılım Çıktısı (Kümeleme Çalışması İçin / 27 veri – 4 grup)

```

» p=[-1.787056497      0.52921476      0.079244153      0.886084304      -1.354866746      -
2.388178256      0.640394999      0.165360017      -0.145948726      -0.793050438      1.282570293
      0.520565691      -0.174902886      -0.266612023      0.339968957      -0.233835819
      0.481959615      -1.65796181      -0.172559943      0.629429292      -1.267843105
      1.214714526      1.684766046      0.882225847      0.899336963      -0.04478998
      0.051770767;
-0.830047064      -1.716144091      1.023844263      -1.342871051      0.684003828      0.153104082
      0.160828022      0.061660343      1.352215812      -0.283041133      0.159791484      -
0.750464281      -0.285206668      1.545383916      -0.880364006      -1.775671016      1.606492553
      1.609604838      -0.923929287      0.120347079      1.38128442      0.020321956      -
0.880911297      -0.659541121      0.768204734      -0.545640979      0.226744666;
1.59240872      -0.554709241      0.066485766      -0.540951522      2.147795835      0.72677466
      0.374426519      -0.158628309      -0.972186471      1.91559371      -0.381342873
      1.369207442      -0.538039749      -0.653987149      -0.233296253      -0.871069087      -
1.544136365      0.134586222      -0.924072232      -0.191447025      -0.412534154      -0.878950246
      -1.716716354      0.173602969      1.088130461      -0.012196687      0.995251414;
-0.389202318      -1.349154177      0.506126112      0.585777962      -0.469294205      -0.43765474
      1.068507203      0.791452354      -0.066953488      -1.111856346      0.916840198      -
0.27553779      0.799484372      -2.855469296      0.846824813      1.830184397      0.750245099
      -0.328115134      -2.076523798      0.283776501      0.578362784      0.202091661
      0.268803203      0.368130551      -0.106569335      0.344913004      -0.675189583]

```

p =

Columns 1 through 7

```

-1.7871  0.5292  0.0792  0.8861 -1.3549 -2.3882  0.6404
-0.8300 -1.7161  1.0238 -1.3429  0.6840  0.1531  0.1608
1.5924 -0.5547  0.0665 -0.5410  2.1478  0.7268  0.3744
-0.3892 -1.3492  0.5061  0.5858 -0.4693 -0.4377  1.0685

```

Columns 8 through 14

```

0.1654 -0.1459 -0.7931  1.2826  0.5206 -0.1749 -0.2666
0.0617  1.3522 -0.2830  0.1598 -0.7505 -0.2852  1.5454
-0.1586 -0.9722  1.9156 -0.3813  1.3692 -0.5380 -0.6540
0.7915 -0.0670 -1.1119  0.9168 -0.2755  0.7995 -2.8555

```

Columns 15 through 21

```

0.3400 -0.2338  0.4820 -1.6580 -0.1726  0.6294 -1.2678
-0.8804 -1.7757  1.6065  1.6096 -0.9239  0.1203  1.3813
-0.2333 -0.8711 -1.5441  0.1346 -0.9241 -0.1914 -0.4125
0.8468  1.8302  0.7502 -0.3281 -2.0765  0.2838  0.5784

```

Columns 22 through 27

```

1.2147  1.6848  0.8822  0.8993 -0.0448  0.0518
0.0203 -0.8809 -0.6595  0.7682 -0.5456  0.2267
-0.8790 -1.7167  0.1736  1.0881 -0.0122  0.9953
0.2021  0.2688  0.3681 -0.1066  0.3449 -0.6752

```

» w=initc(p,4)

w =

```

-0.3517 -0.0830  0.2155 -0.5126
-0.3517 -0.0830  0.2155 -0.5126

```

```
-0.3517 -0.0830 0.2155 -0.5126
-0.3517 -0.0830 0.2155 -0.5126
```

```
» df=100;
» me=10000;
» lr=0.1;
» tp=[df me lr];
» w=trainc(w,p,tp)
TRAINC: 0/10000 epochs.
TRAINC: 100/10000 epochs.
TRAINC: 200/10000 epochs.
TRAINC: 300/10000 epochs.
TRAINC: 400/10000 epochs.
TRAINC: 500/10000 epochs.
...
TRAINC: 9500/10000 epochs.
TRAINC: 9600/10000 epochs.
TRAINC: 9700/10000 epochs.
TRAINC: 9800/10000 epochs.
TRAINC: 9900/10000 epochs.
TRAINC: 10000/10000 epochs.
```

```
w =
```

```
-0.4874 1.3808 -0.4623 -0.2075
0.5663 -0.1532 -0.1414 0.7280
0.6033 -1.2425 -0.8101 -0.0039
-0.6442 -0.0588 1.3815 -0.5542
```

```
» a=simuc(p,w)
```

```
a =
```

```
(4.1) 1
(3.2) 1
(1.3) 1
(3.4) 1
(4.5) 1
(4.6) 1
(2.7) 1
(2.8) 1
(1.9) 1
(4.10) 1
(2.11) 1
(4.12) 1
(2.13) 1
(1.14) 1
(2.15) 1
(3.16) 1
(1.17) 1
(1.18) 1
(3.19) 1
(2.20) 1
(1.21) 1
(2.22) 1
(3.23) 1
(2.24) 1
(2.25) 1
(2.26) 1
(4.27) 1
```

ÖZGEÇMİŞ

1971 yılında İstanbulda doğdu. 1989'da İzmir Bornova Anadolu Lisesi'nden, 1993'de ise İTÜ İşletme Fakültesi Endüstri Mühendisliği Bölümü'nden mezun oldu. Aynı yıl İTÜ Fen Bilimleri Enstitüsü Endüstri Mühendisliği Anabilim Dalı, Mühendislik Yönetimi Programı'na girdi ve 1995'de mezun oldu. Daha sonra bir yıl süresince Assist Consulting Danışmanlık Şirketi'nde asistan danışman olarak çalıştı. 1996'da İTÜ Fen Bilimleri Enstitüsü Endüstri Mühendisliği Anabilim Dalı, Endüstri Mühendisliği Programı'nda doktora çalışmalarına başladı ve aynı yıl İTÜ İşletme Fakültesi Endüstri Mühendisliği Bölümü'nde Araştırma Görevlisi olarak çalışmaya başladı. Halen aynı görevini sürdürmektedir.