

**YILDIZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

**TÜRKİYE’DE PERAKENDE SEKTÖRÜNDE TALEBİ
ETKİLEYEN ETMENLER VE YAPAY SİNİR
AĞLARIYLA TALEP TAHMİNİ UYGULAMASI**

Matematik Mühendisi Zeynep Seda SERTTAŞ

**FBE Endüstri Mühendisliği Anabilim Dalı Endüstri Mühendisliği Programında
Hazırlanan**

YÜKSEK LİSANS TEZİ

Tez Danışmanı : Yrd. Doç. Dr. Bahadır GÜLSÜN (YTÜ)

İSTANBUL, 2011

İÇİNDEKİLER

	Sayfa
KISALTMA LİSTESİ	iv
ŞEKİL LİSTESİ	v
ÇİZELGE LİSTESİ	vi
ÖNSÖZ	vii
ÖZET	viix
ABSTRACT	ix
1. GİRİŞ	1
2. TALEP TAHMİNİ	3
2.1 Talep Tahmini nedir ve Niçin Kullanılır?	3
2.2 Etkin Talep Tahmini İçin Dikkate Alınacak Hususlar	5
2.3 Literatür Taraması	6
3. YAPAY SİNİR AĞLARI	11
3.1 Biyolojik Sinir Sistemi	12
3.2 Yapay Sinir Hücresi	13
3.3 Yapay Sinir Ağlarının Yapısı	15
3.4 Yapay Sinir Ağlarının Genel Özellikleri	16
3.4.1 Doğrusal olmama	16
3.4.2 Hata toleransı	16
3.4.3 Öğrenme	17
3.4.4 Genelleme	17
3.4.5 Uyarlanabilirlik	17
3.4.6 Donanım ve hız	17
3.4.7 Analiz ve tasarım kolaylığı	18
3.4.8 Diğer karakteristikler	18
3.5 Kullanım Alanları	21
3.6 Klasik Yöntemlerle Olan Benzerlikler	22
3.7 Yapay Sinir Ağlarının Sınıflandırılması	23
3.8 Yapay Sinir Ağlarında Öğrenme	24
3.9 Yapay Sinir Ağlarının Mimarisi	25
3.10. Geri Yayılım Algoritması ve Çok Katmanlı Algılayıcı (ÇKA) Modeli	27
3.10.1 ÇKA öğrenme algoritması	27
3.10.2 ÇKA ağının çalışma yöntemi	31
3.10.3 Ağın performansının belirlenmesi	34
3.10.4 Girdi ve çıktılarının ölçeklendirilmesi	34
3.11 Yapay Sinir Ağları Tarihçesi	34

4.	METODOLOJİ VE VERİ SEÇİMİ.....	38
4.1	Metodoloji Seçimi	38
4.2	Veri Seçimi	39
4.3	Verinin Düzenlenmesi	40
5.	UYGULAMA.....	44
5.1	Multilayer Perceptron (Çok Katmanlı Algılayıcı).....	51
5.2	Generalized Feed Forward (Genelleştirilmiş İleri Besleme).....	51
5.3	Modular Neural Networks (Modüler Sinir Ağları)	52
5.4	Jordan And Elman Network (Jordan Ve Elman Ağı).....	52
5.5	Principal Component Analysis (PCA) (Temel Bileşen Analizi).....	53
5.6	Rbf / Grnn / Pnn Network (Rbf) (Radyal Temelli Fonksiyon / Genelleştirilmiş Regresyon Olasılıksal Ağlar)	53
5.7	Self - Organizing Feature Map Network (Kendi Kendini Organize Eden Nitelik Haritası Ağları).....	54
5.8	Time-Lag Recurrent Network (Gecikmeli Tekrarlanan Ağlar).....	55
5.9	Recurrent Network (Yinelenen Ağlar)	55
5.10	Canfis Network (Fuzzy Logic) (Canfis Ağı - Bulanık Mantık)	56
5.11	Support Vector Machine (Destek Vektör Makinesi).....	56
5.12	Uygulama Sonuçları	61
6.	SONUÇLAR.....	65
	KAYNAKLAR.....	67
	EKLER	72
Ek 1	Kullanılan Veri.....	72
Ek 2	Kullanılan Veri (Düzenlenmiş ve Çevrilmiş)	75
	ÖZGEÇMİŞ.....	80

KISALTMA LİSTESİ

SKU	Stock Keeping Unit/Stok Tutma Birimi
YSA / ANN	Yapay Sinir Ağları / Artificial Neuro Networks
SA / NN	Sinir Ağları / Neuro Networks
XOR	Ya da
SOM	Self Organizing Feature Maps / Kendi Kendine Öğrenen Haritalar
ART	Adaptif Rezonans Teorisi
RBF	Radial Basis Functions / Radyal Tabanlı Fonksiyonlar
PNN	Probabilistik Ağlar
GRNN	Genel Regresyon Ağlarını
NNUGA	Neural Network Using Genetic Algorithm
SANN	Statistica Automated Neural Networks

ŞEKİL LİSTESİ

	Sayfa
Şekil 2.1 Talep yönetimi konulu makalelerin sayısı.....	10
Şekil 3.1 Sinir sisteminde bilgi akışı	12
Şekil 3.2 Biyolojik sinir hücresi ve bileşenleri.....	12
Şekil 3.3 Biyolojik hücrenin neurotransmitter'ler yoluyla bilgi alışverişi	13
Şekil 3.4 Yapay sinir hücresi.....	14
Şekil 3.5 Etkinlik fonksiyonu örnekleri.....	15
Şekil 3.6 Yapay sinir ağı örneği	16
Şekil 3.7 İleri beslemeli üç katmanlı YSA	26
Şekil 3.8 Geri beslemeli YSA	27
Şekil 3.9 Çok katmanlı algılayıcı modeli.	28
Şekil 3.10 ÇKA çalışma yöntemi.	31
Şekil 3.11 Hata uzayında öğrenmenin gösterilmesi.	32
Şekil 3.12 Öğrenme sırasında oluşan yerel çözümler.....	32
Şekil 5.1 NS Excel modülü çalıştırılır.	46
Şekil 5.2 Eklentiler kısmında Neurosolutions.	46
Şekil 5.4 Sembollerin işaretlenmesi.	47
Şekil 5.5 Girdi parametrelerinin belirlenmesi.	48
Şekil 5.6 Çıktı sütununun işaretlenmesi.	48
Şekil 5.7 Eğitim satırlarının işaretlenmesi.....	49
Şekil 5.8 Üretim satırlarının işaretlenmesi.	49
Şekil 5.9 Ağın oluşturulması.	50
Şekil 5.10 NeuroBuilder ve ağ çeşitleri.....	50
Şekil 5.11 MLP ağının programdaki görüntüsü.	51
Şekil 5.12 Generalised Feedforward ağının programdaki görüntüsü.	51
Şekil 5.13 Modüler sinir ağının programdaki görüntüsü.....	52
Şekil 5.14 Jordan ve Elman ağının programdaki görüntüsü.....	53
Şekil 5.15 PCA ağının programdaki görüntüsü.....	53
Şekil 5.16 RBF ağının programdaki görüntüsü.....	54
Şekil 5.17 Kohonen özörgütlemeli haritası.	54
Şekil 5.18 SOFM ağının programdaki görüntüsü.....	55
Şekil 5.19 TLRN ağının programdaki görüntüsü.....	55
Şekil 5.20 Yinelenen ağların programdaki görüntüsü.....	56
Şekil 5.21 Canfis ağının programdaki görüntüsü.....	56
Şekil 5.22 SVM ağının programdaki görüntüsü.....	57
Şekil 5.23 Topoloji ekranı.	59
Şekil 5.24 İletim işlevi ve öğrenme kuralları	59
Şekil 5.25 Ağın eğitiminin başlatılması.	60
Şekil 5.26 Sembolik değerlerin sayısal değerlere çevrilmesi.	60
Şekil 5.27 Öğrenme için devir sayısının belirlenmesi.....	61
Şekil 5.28 Öngörülen eğitim süresi.	61

ÇİZELGE LİSTESİ

	Sayfa
Çizelge 2.1 Tahminlemede kullanılan bilimsel yöntemler.	8
Çizelge 3.1 Biyolojik sinir hücresi ile yapay sinir hücresi arasındaki ilişki.....	15
Çizelge 3.2 Çeşitli sinir ağı modellerinin zayıf ve kuvvetli yönleri (Bayraktaroğlu, 1996). .	22
Çizelge 5.1 Ağ sembolleri.	44
Çizelge 5.2 Yapay sinir ağları modelleri.	57
Çizelge 6.1 Eğitimler.....	62
Çizelge 6.2 Son ve minimum hatalar	62
Çizelge 6.3 Sistemden elde edilen tahminler	64

ÖNSÖZ

Yıllar boyu süren araştırmalar, deneyler gözlemler tarihin çoğu kez tekerrürden ibaret olduğunu, gelecek için tahminde bulunurken geçmişi muhakkak incelemek gerektiğini göstermiştir. Müşterilerin ihtiyaçları, coğrafik, demografik, psikolojik, sosyokültürel ve kullanıcıya sağladığı faydaya göre farklılık göstermektedir . Bununla birlikte, müşterinin ihtiyaç ve ortalama alışveriş davranışını tespit etmek, tahminin anahtar noktasıdır. Bu tez çalışmasında tüm bu etkenleri ele alabilecek bir yöntem olarak seçilen yapay sinir ağlarıyla talep tahmini yapılmıştır. Türkiye’de perakende sektöründe talebi etkileyen etmenler bu veriler ışığında kıyaslanarak tespit edilmiştir.

Konu ile ilgili teşviki ve yardımları için tez danışmanım Yrd. Doç. Bahadır Gülsün’e ve bana her konuda destek olan aileme sonsuz teşekkürlerimi sunarım.

ÖZET

Bir ürün, müşteriye ulaşana dek; hammadde tedarikçileri, üreticiler, dağıtıcı bayiiler, nakliyeciler ve perakendecilerden oluşan uzun ve karmaşık bir tedarik zincirinden geçmektedir. Bu zincirde yaşanan herhangi bir aksama ya da zincirin halkaları arasındaki en ufak bir kopukluk bile oldukça büyük maliyetlere yol açabilmektedir. Bu maliyetlerin önüne geçebilmenin kilit noktası, önceden bir planlamanın yapılabilmesidir. Önemli günler, mevsimler, ürünün satılabileceği farklı sezonlar, fiyat değişiklikleri, farklı segmentteki müşteriler ve müşteri profilleri, ürün için yapılan promosyonlar ve hatta ikame ürünlerin promosyonları ile ürünün talebi sürekli değişiklik göstermektedir. Bu kadar çok parametresi bulunan ve talebi sürekli dalgalanmalar gösteren ürünlerin talep tahminini yapmak, ürünün talebini asıl etkileyen nedenleri tespit etmek, süreci doğru yönetebilmenin kilit noktasıdır. Bu amaçla bu tez çalışmasında talebi etkileyen etmenler, Yapay Sinir Ağları (YSA) yardımıyla tespit edilmeye çalışılmıştır. Bir süpermarkette günlük ve mevsimsel olarak satışları önemli ölçüde değişebilen bir ürün için, yapay sinir ağlarıyla talepler tahmin edilmiş, seçilen en uygun ağ modeli ile parametreler kaldırılarak ayrıca bir tahmin yapılmıştır. Çalışmanın sonunda iki durum kıyaslanmıştır.

Anahtar kelimeler : Perakende, talep tahmini, yapay sinir ağları, promosyon (etkisi), tedarik zinciri.

ABSTRACT

A product goes through a long and complex chain of procurement that consists of raw material suppliers, producers, distributors, transporters and retailers until it reaches to the end customer. Any setback on this chain or a disconnection even in the smallest link could lead to great costs. The key point in preventing these costs is, being able to make plans beforehand. Important days, seasonal factors, different seasons that the product can be sold, price changes, customers from different segments and customer profiles, promotions for the product and even promotions of substitute products, demand for the product constantly changes. Demand forecasting of these products that have too many parameters and whose demand constantly fluctuate, establishing the main reasons of demand on the product, are the key points to administer the process. For that purpose, factors that affect demand are tried to be established with the help of Artificial Neural Networks (ANN). For a product in a supermarket whose daily and seasonally sales change significantly, demands were forecasted with artificial neural networks, there has been another forecast with the most convenient network model selected and parameters removed. In the end of these two operations, two circumstances are compared to each other.

Keywords : Retail, demand forecast, artificial neural Networks, promotion, supply chain.

1. GİRİŞ

Tahmin etmek zordur, hem de gelecek için bir tahmin yapıyorsanız. Fakat bununla birlikte, insanoğlu alışkan bir canlıdır; yarın ne yapacağını görmek için ya onu bugün gözlemle ya da ona dün ne yaptığını sor (Ziff, 1971), diye tariflemiş insanoğlunu bir düşünür. Yıllar boyu süren araştırmalar, deneyler, gözlemler tarihin çoğu kez tekerrürden ibaret olduğunu, gelecek için tahminde bulunurken geçmişini muhakkak incelemek gerektiğini göstermiştir. Bilinen bir söz vardır ki, “geleceğin aynası geçmiştir” (Armstrong vd., 2000).

Günümüzün karmaşık dünyasında yönetim, sonuçları bir saatten, bir güne hatta yıllara göre önem arz eden bir planlama ve karar verme süreci ile karşı karşıyadır. Böyle bir durumda tahmin bir lüks değil bir gereklilik halini almıştır. Türkiye’deki bu geniş rekabet ortamı ve “hard discount*” kültürün oldukça yaygınlaştığı perakendecilik ortamında stok değerlerini düşürmek amacıyla öngörülen az stoktan daha tehlikelisi, az stok sebebiyle mağazalarda ürünün temin edilemeyerek satış kaybı; dolayısıyla çoğu zaman da müşteri kaybı yaşamaktır. Bu da “tahmin”in envanter kontrol sisteminin kalbi olduğunun bir başka ifadesidir.

Küresel ekonomide 2007 sonu itibariyle baş gösteren yavaşlama 2008’de yerini durgunluğa, 2009 yılında ise küçülmeye bırakmıştır. Günümüzde başarılı olmak ve başarı sürekliliğini koruyabilmek:

- Dinamik maliyet yönetimi yapabilmeyi,
- Müşteri deneyimini doğru değerlendirmeyi,
- İnsan kaynaklarını doğru yönetebilmeyi,
- Dinamik risk yönetimi, vb. unsurları kapsayan öngörüselle analizlere dayalı bir “bilgi odaklılık” gerektirmektedir.

Bu unsurların her birinin diğeri ile çok sıkı bağlantısı bulunmaktadır.

Perakende sektöründe elektronik perakende, kozmetik, gıda, tekstil, market zincirleri, vb. çok farklı kategoriler bulunmaktadır. Sektördeki firmalar hedeflerini doğru belirlemek ve hedeflerine ulaşmalarını sağlayacak stratejileri kurgulamak, anlık gidişata uygun ikincil, hatta üçüncül planlarını oluşturmak zorundadırlar.

Pazarlama yöneticileri, pazar genişliğinin ve büyüme hızının nasıl olacağını doğru tahmin etmek durumundadırlar. Bir ürün için toplam pazar genişliğinin ne kadar olduğu; hedef pazarın genişliğinin ne olduğu, çeşitli bölgesel ve tüketici pazar bölümlerinin ne kadar

* Büyük ucuzluk

olduğu; gelecekte bu büyüklüklerin nasıl değişeceği; firmanın, satış potansiyelinin ne kadarını değerlendirebildiği; ürünlerin satış hacminin dönemsel trendi; ürün bazında, bölge bazında, nokta bazında beklenen dönemsel satış değerlerinin ne olduğu; satış rakamları üzerindeki etkilerinin ne olduğu; satış rakamlarının düşüş trendinde olan bir ürün için hangi pazarlama faaliyetleri ile trendi artış yönüne çevirebildiğinin tespiti pazarlama amaç ve planlarının doğru biçimde ortaya konulması için ve maliyetlerin, insan kaynaklarının doğru yönetimi için gereklidir. Bunlar tabi ki perakende sektörünün incelenmesi gereken başka boyutlarıdır. Fakat her biri talep tahminini önemli derecede etkileyen, daha uzun vadede etkilerini gösteren belirleyici parametrelerdir.

Tedarik zincirinde başarı veya başarısızlık, en son olarak nihai tüketici tarafından belirlenir. Doğru ürüne, en uygun zamanda ve en uygun fiyatta sahip olmak sadece başarılı bir rekabet için değil aynı zamanda hayatta kalabilmek için de önemli bir anahtardır. Bu yüzden müşteri memnuniyetini arttırmak ve pazarı iyi anlayabilmek, yeni bir tedarik zinciri kurmak için önemli elementler arasındadır.

Başarılı bir tedarik zinciri performansı sağlanabilmesi için, düşük maliyet ve yüksek müşteri memnuniyetinin yanı sıra, talebin ve kaynağın eşleşmesi gerekmektedir. Bunun gerçekleşebilmesi için de tedarik zincirindeki belirsizliklerin mümkün olduğunca giderilmesi gerekmektedir. Bununla birlikte, bazen tedarik zincirinde belirsizlikleri gidermek mümkün olmayabilir. Bunun bir nedeni de ürün çeşididir. Örneğin, ürün son zamanlarda oldukça gözde ve tercih edilen bir ürün ise, bu ürüne olan talep oldukça belirsizdir. Bu durumda, tedarik zinciri bu belirsizliğin varlığını kabul etmek zorunda kalır ve talep ile kaynağı eşleştirebilmek için çeşitli stratejiler belirmeye çalışır (Mason-Jones vd., 2000).

Bir ürünün halihazırdaki ve potansiyel (gelecekteki) alıcılarının toplamı, bu ürünün pazarını oluşturur. Pazar talebi; bir ürünün belirli bir tüketici grubu tarafından; belirli bir coğrafi bölgede, belirli bir zaman aralığında, belirli pazar şartlarında ve pazarlama programı çerçevesinde satın alınabilecek toplam miktarı olarak tanımlanır. Pazar talebinin doğru tahmin edilmesi, belirli bir zaman dilimi için doğru talep tahmini yapılmasını gerektirir. Zaman değiştikçe, yapılan talep tahmini de güncellenir. Bir firmanın bulunduğu pazarda ürünlerine olan talep; pazarlama faaliyetleri, rakiplerin pazarlama faaliyetleri, müşteri deneyimlerinin doğru yönetilmesi vb. faktörler ile ilişkilidir. Perakende şirketleri pazarlama yatırımlarını yönetirken bir taraftan da talep üzerinde yaptığı etkiyi doğru analiz etmek durumundadırlar.

2. TALEP TAHMİNİ

Talep tahmini, envanter yönetiminden nakliye, dağıtım, yenileme, üretim, bakım-onarım, tedarikçi koordinasyonuna bir çok iş operasyonunda geniş bir yelpazede kullanılmaktadır (Fildes vd., 2006; Kusters vd., 2006). Etkili kullanıldığında talep tahmini, şirketlerin ya da tedarik zincirlerinin değişen pazar şartlarına kolayca ayak uydurabilmelerine ve operasyonda kolaylık sağlanabilmesine yardımcı olur (Fildes ve Beard, 1992; Gardner, 1990; Wacker ve Lummus, 2002). Performans düştüğünde, şirketler genellikle öz varlıklarına, hızlandırılmış ve sonucu çabuk alınabilen hizmetlere, diğer pahalı aksiyonlara ve temel hizmetlerine yönelirler (Armstrong, 1988; Winklhofer vd., 1996).

Tahmin etmek zordur, hem de gelecek için bir tahmin yapıyorsanız. fakat bununla birlikte, insanoğlu alışkan bir yaratıktır; yarın ne yapacağını görmek için ya onu bugün gözlemle yada ona dün ne yaptığını sor (Ziff, 1971), diye tariflemiş insanoğlunu bir düşünür. Yıllar boyu süren araştırmalar, deneyler gözlemler tarihin çoğu kez tekrardan ibaret olduğunu, gelecek için tahminde bulunurken geçmişini muhakkak incelemek gerektiğini göstermiştir.

2.1 Talep Tahmini nedir ve Niçin Kullanılır?

Talep tahmini, gelecekteki satışların ne olabileceğini tahmin etmeyi mümkün kılacak şekilde eldeki bilginin düzenlenme ve analiz edilme sürecidir. Hangi üründen ne kadar sipariş verileceği, tüketicilerin bu üründen ne miktar talep edecekleri ve bu talebin yoğunlukla hangi tarihlerde gerçekleşme olasılığının bulunduğu talep tahminleri ile yorumlanır.

Talep tahminlerinin geliştirilmesi, öncül taleplerin belirlenmesi ve ardından formel taleplerin tespitini içeren çok aşamalı bir süreç niteliği taşımaktadır (Kress ve Snyder, 1994). Ürünün talebini etkileyen iç ve dış faktörlerin saptanması ve değerlendirilmesinin ardından ürüne ilişkin öncül tahminler geliştirilmektedir. Bu tahminler ışığında firmalar pazarlama stratejilerini oluşturarak formel taleplerini tespit etmektedirler. Sürecin sonunda artık yapılan tahminlerin verimliliği izlenmektedir. Yapılan tahminlerin gerçekleşen durumlarda ne kadar tutarlı sonuçlar verdiğini gözlemlemek ve duruma göre tedbirler almak önem taşımaktadır.

Karar süreçlerinde “kalitatif” ve “kantitatif” olarak sınıflandırılabilir tahminleme teknikleri kullanılmaktadır. Karar vericilerin öncelikli olarak yapması gereken sorunun yapısına en uygun tahminleme tekniğini belirlemektir. Tahminleme faaliyetleri; tahmin tipi, kapsanan zaman, erişilebilir bilgi kaynakları ve kullanılan tahminleme tekniklerinin ortak bir fonksiyonu niteliğinde olmalıdır (Monks, 1987).

İşletmelerin karar verme sürecinde kullanacakları tahminleme tekniklerinin seçilmesinde; tahminlerin kapsadığı zaman aralığı, tahminlerin hazırlanması için gerekli olan zaman süresi, tahminlerin sonuçlarına göre verilecek kararların uzun veya kısa vadeli oluşu, verilere erişebilme, elde edilen verilerin niteliği ve seyri, tahminleme sürecinde kullanılan kaynakların maliyeti, karar vericinin tolere edebileceği hata payı, tekniğin anlama ve uygulama açısından kolaylığı, yöntemi uygulayacak ve tahminleri kullanarak kararlar verecek olan bireylerin özellikleri v.b. pek çok faktörün dikkate alınması gerekmektedir (Schroeder, 1989; Klassen ve Flores, 2001).

Tahminlemede kullanılan tekniklerden kalitatif tahminleme teknikleri, mevcut durumlara ve gelecekle ilgili planlara ilişkin bilgisi olması beklenen kişilerin fikir ve yargılarının toplanmasını gerektirmektedir (Monks, 1987). Uzmanların görüşleri, bireysel deneyim ve yargılar ile subjektif faktörler ele alınabilmektedir (Render ve Stair, 2000). Kalitatif teknikler, tahminlenecek olguya ilişkin sayısal verilerin elde edilememesi, belirsizliğin ve verilerin değişkenliğinin fazla olması durumunda kullanılabilir. Subjektif faktörlerin ele alınmasını sağlayan kalitatif tahminleme tekniklerinin girdileri çeşitli kaynaklardan elde edilebilmektedir. Bu bilgi kaynakları, müşteriler, satış elemanları, yöneticiler, teknik elemanlar veya işletme dışından çeşitli uzmanlar olabilmektedir (Stevenson, 1989).

Karar verme sürecinde kullanılan başlıca kalitatif teknikler Delphi Tekniği, Pazar Araştırmaları, Uzman Grup Görüşleri ve Satış Gücü Karması olmak üzere dört grupta toplanabilmektedir (Demir ve Gümüşoğlu, 2003). Kalitatif teknikler soyut faktörlerin ve subjektif deneyimlerin ele alınabilmesini sağlamasına karşın, karar verme sürecinde kişisel önyargı ve eğilimlerin yer almasından dolayı genellikle daha düşük performansa sahip tahminlerle sonuçlanmaktadır.

Kalitatif tekniklerde olduğu gibi uzmanların yargı ve görüşlerine yani kalitatif verilere değil, sayısal verilerin analiz edilmesine ve çeşitli istatistiksel metotların sonuçlarına dayanan kantitatif tahminleme tekniklerinin işletmelerin karar verme sürecinde kullanılabilmesi için ise tahminlenecek değişkene veya duruma ilişkin sayısal verilere ulaşılması gerekmektedir. Kantitatif tekniklerde yararlanılan sayısal veriler; barkod teknolojisi, satış noktası verileri ve müşterilerden elde edilebilmekte ayrıca doğru bilgilere ulaşılabilmesi için bilişim teknolojilerinden de faydalanılabilmektedir.

Örneğin CRM yazılımları ile müşteriler hakkında elde edilen bilgiler veritabanlarında saklanabilmekte ve ERP çözümleri ile bu bilgiler tedarik zincirindeki diğer işletmelerle de paylaşılabilmektedir (Sanders ve Manrodt, 2003). Günümüz teknolojisi öyle iyi bir araçtır ki

anlık kasalardan geçen ürünlerin miktar, promosyon, ad, miktar gibi tüm bilgileri elde etme kolaylığı sağlamaktadır. Bu çerçevede müşteri sadakat programları çerçevesinde tasarlanan kartlar ile müşteri sadakatini, belli bir müşteriye ait satın alınan ürün portföyünü belirlemek dahi mümkün olabilmektedir. Bu tür veriler veri madenciliği çerçevesinde de değerlendirilmektedir.

2.2 Etkin Talep Tahmini İçin Dikkate Alınacak Hususlar

Çoğu zaman her iki tarafa da avantaj sağlayan bilişim teknolojilerindeki hızlı gelişmeler tedarikçi ile perakendeci arasında bilgi paylaşımını kaçınılmaz bir hale gelmiştir (Maltz ve Srivastava, 1998). Bu sebeple talep tahmini, üretim planlama çalışmasının temelini oluşturur. Üretilmesi yada satışı düşünülen ürüne ne kadar talep olacağını bilmeden yapılan bir planlama gerçek bir planlama sayılamaz. Talep tahmini ile satın alma işlemleri daha verimli yapılabilecektir. Tüketici pazarında hizmet veren birçok firma talep tahmini yapmaktadır. Talebi etkileyen faktörler düzgün ve sürekli olduğunda ortalama alınarak yapılacak tahminler isabetli olmaktadır. Özellikle envanter çeşit ve seviyesi düşük küçük işletmelerde bu hesaplar şirket sahiplerini yanıltmamaktadır (Kerkkanen vd., 2009). Fakat şirket ve envanter seviyeleri büyüdükçe talebi tahmin etmek için farklı araçlar, yöntemler kullanılmakta, farklı faktörler hesaba katılmak durumundadır.

Müşterilerin ihtiyaçları, coğrafik, demografik, psikolojik, sosyokültürel ve kullanıcıya sağladığı faydaya göre farklılık göstermektedir (Kayhan, 2003). Bununla birlikte, müşterinin ihtiyaç ve ortalama alışveriş davranışını tespit etmek, tahminin anahtar noktasıdır. Müşteri ihtiyaç ve alışveriş davranışları her ne kadar hesaplanabilir değişkenler içermese de bu konudaki en aydınlatıcı veri aslında geçmişte yatmaktadır. Bu sebeple zaman serileri analizi ve stokastik modeller bu tür problemlerin çözümünde yaygın olarak kullanılmaktadır. Buradaki bir önemli nokta da o periyottaki satışı etkileyen faktörleri tespit etmek, bu değişkenleri hesaplanabilir duruma getirmek ve bunları göz önünde bulundurmaktır. Talep analizi, demografik, ekonomik, sosyal ve psikolojik etken, model ve teorilere dayanmaktadır. Bu sebeple “insan dinamikleri” aslında bizi gelecek tahminleri için göz önünde bulundurulması gereken faktörlerdir.

Geçmişe ait satış, tedarik, işlem zamanı, maliyet kayıtları, satış fiyatları bilgisi olmadan geleceği tahmin etmek elbette güçtür. Diğer taraftan tahmincinin de amaçlarını göz önüne alarak toplayacağı bilgilerin cinsi, kapsamını isabetle belirlemesi gerekmektedir. Eksik veya istenilenden daha ayrıntılı bilgiler araştırmanın maliyetini yükselttiği gibi sonuçların duyarlılığını da olumsuz yönde etkiler.

Talep araştırması sonuçlarının kullanılış amacı ile periyodun uzunluğu arasında yakın bir ilişki vardır. Günlük iş emirlerinin hazırlanmasında yararlanılacak tahminlerin aylık periyotlar için yapılması son derece yanıltıcı sonuçlar verebilir. Zira günlük değerlerdeki oynamalar aylık periyotlarda tamamen kaybolur.

Toplanan bilgilerin belirsizlik ve duyarlık gibi nitelikleri ile uygulama amaçları kullanılacak yöntemin seçiminde göz önüne alınması gereken faktörlerdir. Aynı kriterlere, hata hesabının yapılmasında da başvurmakta fayda vardır. Çünkü talep tahmini yapılırken sadece talep tahmini yapmak, onun gerçek hayattaki uygulamadaki başarısını ölçmekten daha önem verilen bir konu olagelmıştır (Mentzer ve Moon, 2005). Bu bakımdan yapay sinir ağları hatanın tespiti konusunda kurulan modelin işlevselliğini ölçmek için avantajlı bir yöntem olmaktadır.

Daha az stokla çalışabilmenin en önemli şartlarından birisi satışların önceden tahmin edilmesidir. Böylece planlama ve emniyet stokunu belirlemek kolaylaşır, stok gün değerleri azalır.

2.3 Literatür Taraması

Literatürde, şirketlerin karar verme mekanizmasında “tahmin”in can alıcı bir nokta olduğu konusunda yoğun bir görüş birliği bulunmaktadır (Remus ve Simkin, 1987; Makridakis, 1990; Galbraith ve Merrill, 1996). Gerçekten de tahminler “bir organizasyonun tüm geleceğini etkileyebilecek tüm kararların giriş parametreleri, girdileridir (McLaughlin, 1979). Buna üretim planlama, satış tahmini, bütçeleme ve pazarlama planlaması da dahildir (Mentzer ve Cox, 1984; Peterson, 1993; West, 1994).

Talep tahminleri tedarik zinciri planlamanın tüm aşamalarını (hammadde sağlayıcısından, üreticisinden, tedarikçisine, lojistikçisinden perakendecisine tüm kanallarını) zincirleme etkilemesi sebebiyle hatasız olması önem taşımaktadır (Yelland, 2006). Ve tedarik zincirinin her seviyesinde başta önemsiz görünecek küçüklükte olan tahminleme hataları hizmet kalitesinde düşüşe, envanter seviyesinde yükselmeye sebep olacak kadar çıg gibi büyümektedir (Fildes vd, 2008). İşte bu sebeple birbiriyle ilişkili veri dizisinde, dış etkenlerin ve dalgalanmaların çok olduğu (Fildes ve Beard, 1992) bu ekonomik ortamda tahminleme işi oldukça zordur. Ve tabi ki tüm bu işlemler onlarca SKU (stock keeping unit *) için yapıldığında her bir periyot için tahminleme yapmak gerekmektedir. tedarik zincirlerinin yönetilmesi ve planlanması için uzmanlar tahminlemede tek bir ürün çeşidini (SKU)

* Stok kodu ya da Ürün çeşidi

seçmektedirler (Fildes vd., 2008). Bu çalışmada da bu zorluk ve karmaşıklık göz önüne alınarak tek bir ürün grubu seçilerek tahminleme yapılmaya çalışılmıştır. Bu ürünün seçiminde hangi kriterlerin dikkate alındığı ve hangi sebeplerle bu ürünün seçildiği, diğer aday ürünlerden neyin bu ürünü özel kıldığı ileriki bölümlerde açıklanacaktır.

Literatürde TZ'deki belirsizlikler ile ilgili üzerinde en fazla durulan konu talep belirsizliğidir. Talep, üretim planlama ve TZ yönetiminde karşılaşılan belirsizliklerin ana kaynağıdır. İmalat sektöründe kapasitelerin planlanması, hammadde siparişlerin verilmesi ve oluşan talebe en kısa zamanda cevap verilebilmesi için taleplerin önceden tahmin edilmesi gerekir (Karabuk ve Wu, 2003). Aynı şekilde perakende sektöründe tedarikçilerin istenilen seviyede ürünleri tedarik edebilmeleri için belli bir süre önceden tedarikçiye öngörülen talep miktarının bildirilmesi ve tedarikçinin de gerekli hammaddeyi temin ederek, üretimini gerçekleştirmesi gerekmektedir. Zincir marketlerde yüksek miktarlarda sipariş gerektiği ve bir çok noktanın satışlarını öngörmek gerektiği için sipariş öncesi talep tahmini oldukça zorlayıcı bir süreçtir. Talep tahminleri geleceğe yönelik öngörüler içerdiği için her zaman belirsizlikleri içerisinde barındırır. Bir şirketin tahminlemenin etkin olduğunu gösteren can alıcı nokta yüksek envanter seviyesi, düşük müşteri hizmeti seviyesi, verimsiz planlanan üretim/satış miktarlarından uzak olmasıdır (Gardner, 1990; Sanders, 1992; Fildes ve Hastings, 1994). Yani taleplerin iyi planlanması firmaların kârlılığını doğrudan etkileyen faktörlerden bir tanesidir. Tahmin ile gerçekleşen miktarlar arasında farklılık olduğunda müşteri ihtiyaçları karşılanamaz veya elde çok miktarda stok tutulmak zorunda kalınır. Her iki durumda da firmalar olası kârlarından feragat ederler (Guillen vd., 2005; Gupta ve Maranas 2003; Karabuk ve Wu, 2003).

Araştırmacıların birçoğu tahminlemenin pratik iş hayatında önemli bir role sahip olduğu ve bir çok makalede modelin geliştirilmesi ve uygulamaya geçirilmesi konusunda yönetsel faktörlerin araştırılması gerektiğini vurgulamışlardır (Fildes, 2006; Makridakis, 1996; Winklhofer vd., 1996). Bu konuda yapılan literatür taramasında tahminlemenin geliştirme ve uygulama çalışmalarında etkenlerin ve aralarındaki ilişkilerin açıklanmasında teorik alt yapı kullanılmıştır (Davis ve Mentzer, 2007; Fildes ve Hastings, 1994; Fildes vd., 2006; Mentzer, Bienstock ve Kahn, 1999; Winklhofer ve Diamantopoulos, 2003). Carlo D. Smith ve John T. Mentzer ise çalışmalarında tahminleme sistemlerinin rolüne dikkat çekmişlerdir (2009).

Talep tahmini tedarik zincirini etkin olarak kullanan firmalarda önemli bir öneme sahiptir. Bu şekilde çalışan şirketlerde talep tahminine en yaygın yaklaşım, bilgisayar tabanlı tahminleme sistemleriyle ilk tahminler elde edilerek olağanüstü dalgalanmalara hazırlıklı olunması

açısından uzman planlamacılar tarafından eleştirel düzeltmeler yapılmasıdır (Fildes vd., 2008).

Matuyama vd. (2008) envanter seviyesinin belli olduğu fakat talebin kesin olmadığı durumlar için yaptıkları çalışmada iki farklı geribildirim politikasıyla iki farklı tahmin formülü kullanarak, envanter sistemine periyodik bir bakış geliştirmişlerdir. Periyot boyunca envanter seviyesindeki değişimi göz önüne alarak, fark eşitliğiyle sipariş miktarını belirleyebilmişlerdir. Çalışmada çıkan sonuca göre, yakın gelecekte talep yaklaşık olarak beklenen değerde ise geribildirim önem kazanmaktadır. Buna karşılık talep tam olarak beklenen değerde ise geribildirim önemi de azalmaktadır.

Fildes vd. (2008) yaptıkları çalışmada herhangi bir bilgisayar tabanlı tahminlemenin ardından çıkan sonuçların tahminleme ve planlama uzmanlarının eleştirel ve iyileştirici müdahaleleri ile hata oranının azalıp azalmadığını tespit etmeye çalışmışlardır. Sistemin hazırladığı verilerin mi daha isabetli tahminler yaptığı ya da uzman görüşleri iyileştirilen tahminlerin mi daha isabetli sonuçlar ortaya çıkardığı hipotezlerini irdelenmişlerdir. Çalışmada dört tedarik zinciri şirketi incelenerek bilgisayar sistemleriyle belirlenen tahminleme üzerine nasıl daha etkin bir uzman iyileştirilmesi yapılabileceğini tespit etmeye çalışmışlardır ve çalışma sonunda zaman görüşünün etkinliğinin firmanın hizmet verdiği sektör ve iyileştirmeyi yapan takımın başarısına bağlı olduğu sonucuna ulaşmışlardır.

Armstrong vd. (2000) talep tahmini için karşılaştırmayı sağlayan ekstrapolasyon yöntemini seçmişlerdir. Geçmiş satışların ekstrapolasyonunu sağlayan bu yöntemi seçmelerindeki amacı kullanışlı ve kolay anlaşılır olması; yöneticilerin geçmiş satış bilgilerine sahip olmaları ve zamana serileri ile tahminleme yapabilmeleri olarak açıklamaktadırlar.


Tahminleme üzerine yapılan çalışmalarda kullanılan metodlar aşağıdaki gibi özetlenebilir (Song ve Li, 2008).

Çizelge 2.1 Tahminlemede kullanılan bilimsel yöntemler.

ADLM	Autoregressive Distributed Lag Model
AIDS	Almost İdeal Demand System
AR	Autoregressive Process
AR(I)MA(X)	Autoregressive (İntegrated) Moving Average (Cause Effect) Model
AS	Additive Seasonality
MS	Multiplicative Seasonality
SF	Seasonal Fractional
In	With İntervention
ANN	Artificial Neural Network
BSM	Noncausal Basic Structural Model

M	Multivariate Bsm
CGE	Computable General Equilibrium Model
CI	Cointegration
Com	Compertz
CP	Cubic Polynomial Model
DC	Decomposition
DSS	Decision Support System
ECM	Error Correction Model
ES	Exponential Smoothing
FTS	Fuzzy Time Series
GA	Genetic Algorithm
GARCH	Generalised Autoregressive Conditional Heteroskedastic Model
GSR	Gradual Switching Regression
HPM	Hedonic Pricing Model
LAIDS	Linear Aids
LCM	The Learning Curve Model
MA	Moving Average
MARIMA	Multivariate Arıma
Nai'ıve 1	Nochange Model
Nai'ıve 2	Constant Growth Rate Model
PAR	Periodic Autoregressive Model
PDR	Panel Data Regression
SEM	Structural Equation Model
SR	Static Regression
STSM	Structural Timeseries Model
SVR	Support Vector Regression
SW	Sine Wave Nonlinear Model
TAS	Technical Analysis System
TCM	Trend Curve Model
TFM	Transfer Function Model
TVP	Time Varying Parameter Model
VAR	Vector Autoregression
DU	Differenced Unrestricted
CS	Cointegrated Structural
VECM	Vector Error Correction Mode

Ayrıca Şekil 2.1’de de görüldüğü gibi 2004’ten önce talep tahminiyle ilgili yayınlanan makalelerin sayıları önemli dalgalanmalar gösterirken, 2005’ten sonra önemli bir gelişme kaydetmeye başlamıştır.



Şekil 2. 1 Talep yönetimi konulu makalelerin sayısı (Ko vd., 2010).

Son zamanlarda yapılan araştırmalar göstermektedir ki Yapay Sinir Ağları, her ne kadar yapısal olarak ağı kurulması zor olsa da doğrusal olmayan modellerde oldukça iyi sonuçlar vermektedir. Şüphesiz ki perakende sektörü tedarik zincirinde en önemli konulardan birisi tahminlemedir (Luxhoj vd., 1996; Thommasey vd., 2005; Sun vd., 2007) ve perakendeci ve beraberinde ilişkili tüm kanalları doğrudan etkilemektedir. Bu sebeple bağdaştırıcı modeller, tahminleme konusunda doğrusal olmama ve gürültü tolerans kapasiteleri olması avantajıyla önemli adaylardır (Frank vd., 2002; Sztandera vd., 2004; Wu vd., 1994, 2004). Temel nokta, ağı geçmiş verilerle eğitmek ve bu veriler ışığında gelecek tahmini için değerler üretmektir.

Son on yıldır tahmin metotları gelişmektedir. Orta ve uzun dönem tahmini için kullanılan son kullanıcı ve ekonomik yaklaşım metotları genel kullanımına yakındır. Benzer gün yaklaşımı, çeşitli regresyon modelleri, zaman serileri, sinir ağları, uzman sistemler, bulanık mantık ve istatistiksel öğrenme algoritmaları gibi çeşitli yöntemler kısa dönem tahmininde kullanılır.

Genelde kullanılan tahmin metotlarını şöyle sıralayabiliriz (Akar, 2005);

1. Zaman serisi analizi,
2. Son kullanıcı modeli,
3. Ortalama artış yüzdeleri ile tahmin,
4. Ekonometrik modeller,
5. Regresyon analizi,
6. Yapay sinir ağları (YSA).

3. YAPAY SİNİR AĞLARI


Dünyada bilgisayarlar ve bilgisayar sistemleri artık yaşamımızın vazgeçilmez bir parçası olmuştur. Çevremizde gördüğümüz yaşamımızı kolaylaştıran mutfaktaki buzdolaplarından cep telefonlarına teknolojik birçok alet bilgisayar sistemi ile çalışmaktadır. İş dünyasından kamu işlerine, çevre ve sağlık organizasyonlarından askeri sistemlere kadar hemen hemen her alanda bilgisayarlardan faydalanmak olağan hale gelmiştir. Teknolojinin gelişmesi izlendiğinde önceleri sadece elektronik veri transferi yapmak ve karmaşık hesaplamaları gerçekleştirmek üzere geliştirilen bilgisayarların zaman içerisinde büyük miktarlardaki verileri filtreleyerek özetleyebilen ve mevcut bilgileri kullanarak olaylar hakkında karar verebilmekte hem de olaylar arasındaki ilişkileri öğrenebilmektedir. Matematiksel olarak formülasyonu kurulamayan ve çözülmesi mümkün olmayan problemler sezgisel yöntemler yolu ile bilgisayarlar tarafından çözülebilmektedir. Bilgisayarları bu özelliklerle donatan ve bu yeteneklerinin gelişmesini sağlayan çalışmalar “yapay zeka” çalışmaları olarak bilinmektedir. Zeki sistemlerin en temel özellikleri olaylara ve problemlere çözümler üretirken veya çalışırken bilgiye dayalı olarak karar verebilme özelliklerinin olması ve eldeki bilgiler ile olayları öğrenerek, sonraki olaylar hakkında karar verebilmeleridir. Yapay zeka bilimindeki gelişmeler bu sistemlerden çeşitlendirmeye neden olmaktadır. Bu gelişmeler ve ticari sistemlerin başarılı şekilde uygulanması yapay zeka teknolojisinin gelişimine ilgiler daha çok çekmiş ve yapay zeka önceleri sadece bir ilgi odağı iken bugün artık bir bilim dalı haline gelmiştir (Öztemel, 2006). Böylece yapay zeka teknolojisi her geçen gün daha fazla gelişerek yeni ürünler ortaya çıkmaktadır. Yapay zeka teknolojilerini şu ana başlıklar altında toplayabiliriz :

- Uzman sistemler
- Makine öğrenmesi ve yapay sinir ağları
- Genetik algoritmalar
- Bulanık önermeler mantığı
- Zeki etmenler.

Aşağıda, örnekleri göz önüne alarak, olaylar arasındaki ilişkileri öğrenerek daha sonra hiç görmediği örnekler hakkında karar verebilen sistemler olan “yapay sinir ağları”nın modellenmesinde baz alınan biyolojik sinir sistemi incelenmektedir.


3.1 Biyolojik Sinir Sistemi

Biyolojik sinir sistemi, merkezinde sürekli olarak bilgiyi alan, yorumlayan ve uygun bir karar üreten beyin bulunduğu 3 katmanlı bir sistem olarak açıklanır. Alıcı sinirler (receptor) organizma içerisinde ya da dış ortamlardan algıladıkları uyarıları, beyne bilgi ileten elektriksel sinyallere dönüştürür. Tepki sinirleri (effector) ise, beyin ürettiği elektriksel darbeleri organizma çıktısı olarak uygun tepkilere dönüştürür.



Şekil 3.1 Sinir sisteminde bilgi akışı (Efe ve Kaynak, 2000).

İnsan beyni nöron olarak adlandırılan yaklaşık 10^{11} hesap elemanından oluşmaktadır. Biyolojik sinir ağını oluşturan nöronlar soma, akson ve dendrit olmak üzere üç bölgeye ayrılır (Şekil 3.2).




Şekil 3.2 Biyolojik sinir hücresi ve bileşenleri (Öztemel, 2006).

Sinapsler, sinir hücreleri arasındaki fiziksel olmayan bir hücreden diğerine elektrik sinyallerini iletilmesini sağlayan boşluklar olarak görülmektedir.

Soma olarak adlandırılan hücre gövdesi, hücreyi denetler ve hücre etkinliklerinin tümünü yönetmekle sorumludur. Soma gelen sinyalleri işleme alarak hücrenin kendi elektrik sinyalini oluşturur. Hücre gövdesinden dendrit ve akson olarak adlandırılan iki uzantı çıkar.

Dendritler hücre gövdesinden dışarı uzanan ağaç dalları biçimindedir. Bilgiyi aksonlar boyunca diğer nöronlardan alarak hücre gövdesine taşırlar. Aksonlar ise gövdedeki bilgiyi diğer nöronların dendritlerine taşımakla görevlidirler. Aksonun son bölümündeki dalların sonunda sinaptik terminaller olarak adlandırılan uçlar ve bu uçlarla diğer hücrelerin dendritleri arasında sinaptik aralıklar bulunmaktadır. Bu aralıklar sinaps ya da kavşak olarak da adlandırılır. Sinapslar, hücrenin kendi sinyali komşu hücreye tanıttığı bağlantı noktasıdır. Elektriksel ve kimyasal özellikte iki tip sinaps olduğu bilinmektedir. Dolayısıyla iki hücrenin bilgi alışverişi sinaptik bağlantılarda neurotransmitter'ler yolu ile sağlanmaktadır (Şekil 3.3).

İnsan beyni belirtilen bu özellikte yaklaşık 10 milyar sinir hücresinden ve 60 trilyon sinaps bağlantısından oluşmaktadır. Bu kadar karmaşık yapıya rağmen, bir sinir hücresinin tepki hızı, günümüz bilgisayarlarına göre oldukça yavaş kalmaktadır. Ancak beynin bilgisayar sistemlerine göre asıl üstünlüğü idrak etme yeteneğinde saklıdır. Ayrıca eksik bilgi ile görme, konuşma, şekil tanıma gibi konularda insan beyni bilgisayarlara karşı ezici üstünlüğe sahiptir.




Şekil 3.3 Biyolojik hücrenin neurotransmitter'ler yoluyla bilgi alışverişi (Öztemel, 2006).

Beynin bu üstün özellikleri, bilim adamlarını üzerinde çalışmaya zorlamış ve aradaki farklılığın insan beynindeki sinirlerin bilgiyi paralel işlemelerinden kaynaklandığı anlaşılmıştır. Bu bulgudan hareketle, beynin yapısından esinlenerek matematiksel modeli çıkarılmaya çalışılmıştır. Böylelikle beynin bu yeteneğini gerçekleyen yöntemler ortaya çıkarılmıştır.

3.2 Yapay Sinir Hücresi

Biyolojik sinir ağlarını oluşturan biyolojik sinir hücrelerinin görevini yapay sinir ağlarında proses elemanları yerine getirmektedir. Proses elemanları düğüm ya da basit sinirler olarak da adlandırılır. Bir yapay sinir ağı birbiriyle bağlantılı çok sayıda düğümden oluşur. Her bir proses elemanının (yapay sinir hücresinin) beş temel bileşeni bulunmaktadır (Şekil 3.4).

1. *Girdiler*: Girdiler ($u_1, u_2, \dots, u_n$) çevreden aldığı bilgileri sinire getirir. Bu bilgiler dış dünya dan olabileceği gibi başka hücrelerden ya da hücrenin kendisinden gelebilir.



Şekil 3.4 Yapay sinir hücresi (Efe ve Kaynak, 2000).

2. *Ağırlıklar*: Ağırlıklar ($w_1, w_2, \dots, w_n$) hücreye gelen bilginin hücre üzerindeki etkisini gösterirler. Ağırlıkların değerinin büyük ya da küçük olması, onların önemini belirleyen bir unsur değildir. O girişin hücreye güçlü bağlanması durumunda ağırlık değeri büyük, zayıf bağlanması durumunda ise ağırlık değeri küçük olur.


3. *Toplama fonksiyonu*: Hücreye gelen net girdiyi hesaplayarak, çıkan sonucu etkinlik (aktivasyon) fonksiyonuna gönderir. Net girdinin hesaplanması için değişik fonksiyonlar kullanılabilir. En çok, hücreye gelen girdi değerleri kendi ağırlıkları ile çarpılarak bulunan ağırlıklı toplam kullanılır (Eş. 3.1).

$$NET = \sum_i^n u_i w_i \quad (3.1)$$

Belirli bir problem için en uygun toplama fonksiyonunun belirlenmesi amacıyla kullanılacak herhangi bir yöntem bulunmamaktadır. Bazen Eş. 3.1'deki basit işlem yerine minimum, maksimum, çarpım ya da kümülatif toplam algoritmaları da kullanılabilir. Ağda bulunan her hücrenin farklı toplama fonksiyonuna sahip olması mümkün olduğu gibi, ağdaki hücrelerden bir kısmı grup olarak aynı toplama fonksiyonuna sahip olabilir.

4. *Etkinlik (Aktivasyon) Fonksiyonu*: Toplama fonksiyonundan alınan sonuç etkinlik fonksiyonundan geçirilerek çıkışa verilir. Burada da değişik fonksiyonlar kullanılabilmekte (Şekil 3.4), bir problemin çözümü için kullanılacak etkinlik fonksiyonunun belirlenebilmesi için herhangi bir yöntem bulunmamaktadır.

5. *Çıktı*: Etkinlik fonksiyonu tarafından belirlenen değerdir. Bu değer birden fazla hücreye girdi olarak gönderilir. Ancak her bir hücrenin tek bir çıkış değeri vardır.



Şekil 3.5. Etkinlik fonksiyonu örnekleri (Efe ve Kaynak, 2000).

a) Sigmoid b) Hiperbolik tanjant c) Sert geçişli

Yapay sinir hücrelerinin tasarımı biyolojik sinir hücrelerinden etkilendiğinden aralarında birtakım benzerlikler bulunmaktadır. Bunlar Çizelge 3.1’de özetlenmiştir.

Çizelge 3.1 Biyolojik sinir hücresi ile yapay sinir hücresi arasındaki ilişki.

Biyolojik Sinir Hücresi	Yapay Sinir Hücresi
Sinir sistemi	Hesaplama sistemi
Sinir	Düğüm, İşlem elemanı, Sinir
Sinaps	Bağlantı ağırlıkları
Dentrit	Toplama fonksiyonu
Hücre gövdesi	Etkinlik (aktivasyon) fonksiyonu
Akson	Sinir çıkışı

3.3 Yapay Sinir Ağlarının Yapısı

Yapay sinir ağlarının oluşabilmesi için yapay sinir hücrelerinin katmanlar dahilinde paralel olarak bir araya gelmesi gerekir. Birbirleriyle olan ilişkileri Şekil 3.6’da gösterilen bu katmanlar genel olarak şu şekilde tanımlanır:


Girdi katmanı: Bilginin işlenmediği, sadece gelen bilgilerin ağı iletildiği katmandır.

Ara (Gizli) katman: Girdi katmanından gelen bilgilerin işlendiği ve çıkış katmanına gönderildiği katmandır. Bir ağda birden fazla ara katman olabilir.

Çıktı katmanı: Ara katmandan gelen bilgiyi işleyerek dış dünyaya gönderen katmandır.

Yapay sinir ağlarının genel çalışma prensibi bir girdi setini (örnekleri) alarak, onları çıktı setine çevirmek olarak açıklanabilir (Öztemel, 2006). Ancak, girdi vektörünün çıktı vektörüne

nasıl dönüştürüldüğü konusunda ağdan bilgi alınamaz. Dolayısıyla, bir yapay sinir ağının nasıl sonuç elde ettiğini açıklama gücü yoktur.



Şekil 3.6 Yapay sinir ağı örneği (Öztemel, 2006).

3.4 Yapay Sinir Ağlarının Genel Özellikleri

Bir sinir ağının en temel bileşeninin beyin yapısından esinlenerek geliştirilmesine karşın bazı özellikleri beyinle aynı değildir. Bazı özelliklerinin ise beyinde biyolojik karşılığı yoktur. Bununla birlikte, sinir ağları biyolojik beyinle büyük benzerlikler gösterir ve bu nedenle terimlerin büyük kısmı sinirbilim'den (neuroscience) alınmıştır (Elmas, 2003).

Yapay sinir ağı sahip olduğu özelliklerden dolayı, alışlagelmiş bilgi işleme yöntemlerinden farklılık göstermektedir. Hatta sahip olduğu bazı özellikler bakımından bir çok yönetime göre daha sağlıklı sonuçlar vermektedir (Şen, 2004). Bu özelliklerinden bazıları doğrusal olmama (paralellik), hata toleransı, öğrenme, genelleme, uyarlanabilirlik, donanım ve hız, analiz ve tasarım kolaylığı olarak tanımlanabilir.

3.4.1 Doğrusal olmama

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

3.4.2 Hata toleransı

Ağ, çok sayıda hücrenin çeşitli şekillerde bağlanmasından oluştuğundan paralel dağılmış bir yapıya sahiptir ve ağın sahip olduğu bilgi, ağdaki bütün bağlantılar üzerine dağılmış durumdadır. Bu nedenle, eğitilmiş bir ağın bazı bağlantılarının hatta bazı hücrelerinin etkisiz hale gelmesi, ağın doğru bilgi üretmesini önemli ölçüde etkilemez. Yapay sinir ağlarının eksik bilgilerle çalışabilme yetenekleri hatalara karşı toleranslı olmalarını sağlamaktadır. Ağın bazı hücrelerinin bozulması ve çalışamaz duruma düşmesi halinde ağ çalışmaya devam eder. Ağın bozuk olan hücrelerinin sorumluluklarının önemine göre ağın performansında düşmeler görülebilir. Hangi hücrelerin sorumluluklarının önemli olduğuna da yine ağ eğitim esnasında kendisi karar verir. Bunu kullanıcı bilmemektedir. Ağın bilgisinin yorumlanamamasının sebebi de budur.

3.4.3 Öğrenme

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

3.4.4 Genelleme

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

3.4.5 Uyarlanabilirlik

YSA, ilgilendiği problemdeki değişikliklere göre ağırlıklarını ayarlar. Yani, belirli bir problemi çözmek amacıyla eğitilen YSA, problemdeki değişimlere göre tekrar eğitilebilir, değişimler devamlı ise gerçek zamanda da eğitime devam edilebilir. Bu özelliği ile YSA, uyarlamalı örnek tanıma, sinyal işleme, sistem tanılama ve denetim gibi alanlarda etkin olarak kullanılır.

3.4.6 Donanım ve hız

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

3.4.7 Analiz ve tasarım kolaylığı

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

3.4.8 Diğer karakteristikler

Yapay sinir ağlarının bütün modelleri için geçerli olan genel karakteristik özellikler aşağıdaki gibi sıralanabilir (Öztemel, 2006) :

Yapay sinir ağları makine öğrenmesi gerçekleştirirler: Yapay sinir ağlarının temel işlevi bilgisayarların öğrenmesini sağlamaktır. Olayları öğrenerek benzer olaylar karşısında benzer kararlar vermeye çalışırlar.

Çalışma stilleri bilinen programlama yöntemlerine benzememektedir: Geleneksel programlama ve yapay zeka yöntemlerinin uygulandığı bilgi işleme yöntemlerinden tamamen farklı bir bilgi işleme yöntemi vardır.

Bilginin saklanması: Yapay sinir ağlarında bilgi ağın bağlantılarının değerleri ile ölçülmekte ve bağlantılarda saklanmaktadır. Diğer programlarda olduğu gibi veriler bir veri tabanında veya programın içinde gömülü değildir. Bilgiler ağın üzerinde saklı olup ortaya çıkartılması ve yorumlanması zordur.

Yapay sinir ağları örnekleri kullanarak öğrenirler: Yapay sinir ağlarının olayları öğrenebilmesi için, o olay ile ilgili örneklerin belirlenmesi gerekmektedir. Örnekleri kullanarak ilgili olay hakkında genelleme yapabilecek yeteneğe kavuşturulurlar (adaptif öğrenme). Örnek bulunamıyorsa yapay sinir ağının eğitilmesi mümkün değildir. Örnekler ise gerçekleşmiş olan olaylardır. Mesela bir doktor hastasına bazı sorular sorar ve aldığı cevaplara göre teşhis ederek ilaç yazar. Sorulan sorular ve verilen cevaplar ile konulan teşhis bir örnek olarak nitelendirilir. Bir doktorun belirli bir zaman içinde hastaları ile yaptığı görüşmeler ve koyduğu teşhisler not edilerek örnek olarak alınırsa yapay sinir ağı benzer hastalıklara benzer teşhisi koyabilir. Elde edilen örneklerin olayı tamamı ile gösterebilmesi

çok önemlidir. Ağa olay bütün yönleri ile gösterilemez ve ilgili örnekler sunulmaz ise başarılı sonuçlar elde edilemez. Bu ağın sorunlu olduğundan değil olayın ağa iyi gösterilemediğindendir. O nedenle örneklerin oluşturulması ve toplanması yapay sinir ağı biliminde özel bir öneme sahiptir.

Yapay sinir ağlarının güvenle çalıştırılabilmesi için önce eğitilmeleri ve performanslarının test edilmesi gerekmektedir: Yapay sinir ağlarının eğitilmesi demek, mevcut örneklerin tek tek ağa gösterilmesi ve ağın kendi mekanizmalarını çalıştırarak örnekteki olaylar arasındaki ilişkileri belirlemesi demektir. Her ağı eğitmek için elde bulunan örnekler iki ayrı sete bölünürler. Birincisi ağı eğitmek için (eğitim seti) diğeri ise ağın performansını sınamak için (test seti) kullanılır. Her ağ önce eğitim seti ile eğitilir. Ağ bütün örneklerle doğru cevaplar vermeye başlayınca eğitim işi tamamlanmış kabul edilir. Daha sonra ağın hiç görmediği test setindeki örnekler ağa gösterilerek ağın verdiği cevaplara bakılır. Eğer ağ hiç görmediği örneklerle kabul edilebilir bir doğrulukta cevap veriyor ise o zaman ağın performansı iyi kabul edilir ve ağ kullanıma alınarak gerekirse çevrimiçi (*on-line*) kullanılır. Eğer ağın performansı yetersiz olursa o zaman yeniden eğitmek veya yeni örnekler ile eğitmek gibi bir çözüme gidilir. Bu işlem ağın performansı kabul edilebilir bir düzeye gelinceye kadar devam eder.

Görülmemiş örnekler hakkında bilgi üretebilirler: Ağlar kendisine gösterilen örneklerden genellemeler yaparak görmediği örnekler hakkında bilgiler üretebilirler.

Algılamaya yönelik olaylarda kullanılabilirler: Ağlar daha çok algılamaya yönelik bilgileri işlemede kullanılırlar. Bu konuda başarılı oldukları yapılan uygulamalarda görülmektedir. Bilgiye dayalı çözümlerde uzman sistemler kullanılmaktadır. Bazı durumlarda yapay sinir ağı ve uzman sistemleri birleştirmek daha başarılı sistemler oluşturmaya neden olmaktadır.

Şekil (örüntü) ilişkilendirme ve sınıflandırma yapabilirler: Genel olarak ağların çoğunun amacı, kendisine örnekler halinde verilen örüntülerin kendisi veya diğerleri ile ilişkilendirilmesidir. Diğer bir amaç ise sınıflandırma yapmaktır. Verilen örneklerin kümelendirilmesi ve belirli sınıflara ayrıştırılarak daha sonra gelen bir örneğin hangi sınıfa gireceğine karar vermesi hedeflenmektedir.

Örüntü tamamlama gerçekleştirebilirler: Bazı durumlarda ağa eksik bilgileri içeren bir örüntü veya bir şekil verilir. Ağın bu eksik bilgileri bulması istenir. Örneğin, yırtık bir resmin kime ait olduğunu belirlemesi ve tam resmi vermesi gibi bir sorumluluk ağdan istenebilmektedir. Bu tür olaylarda yapay sinir ağlarının çok etkin çözümler ürettiği bilinmektedir.

Kendi kendini organize etme ve öğrenebilme yetenekleri vardır: Yapay sinir ağlarının örnekler ile kendisine gösterilen yeni durumlara adapte olması ve sürekli yeni olayları öğrenebilmesi mümkündür.

Eksik bilgi ile çalışabilmektedirler: Yapay sinir ağları kendileri eğitildikten sonra eksik bilgiler ile çalışabilir ve gelen yeni örneklerde eksik bilgi olmasına rağmen sonuç üretebilirler. Eksik bilgiler ile de çalışmaya devam ederler. Halbuki geleneksel sistemler bilgi eksik olunca çalışmazlar. Burada bir noktaya dikkat çekmekte fayda vardır. Yapay sinir ağlarının eksik bilgiler ile çalışması performanslarının düşeceği anlamına gelmez. Performansın düşmesi eksik olan bilginin önemine bağlıdır. Hangi bilginin önemli olduğunu ağ eğitim sırasında öğrenmektedir. Kullanıcıların bu konuda bir fikri yoktur. Ağın performansı düşük olunca, kayıp olan bilginin önemli olduğu kararına varılır. Eğer ağın performansı düşmez ise eksik olan bilginin önemli olmadığı anlaşılır.

Belirsiz, tam olmayan bilgileri işleyebilmektedirler: Yapay sinir ağlarının belirsiz bilgileri işleyebilme yetenekleri vardır. Olayları öğrendikten sonra belirsizlikler altında ağlar öğrendikleri olaylar ile ilgili ilişkileri kurarak kararlar verebilirler.

Dereceli bozulma (Graceful degradation) gösterirler: Yapay sinir ağlarının hatalara karşı toleranslı olmaları bozulmalarının da dereceli olmasına neden olmaktadır. Bir ağ zaman içerisinde yavaş yavaş ve düzenli bir şekilde bozulur. Bu eksik olan bilgiden veya hücrelerin bozulmasından kaynaklanır. Ağlar, herhangi bir problem ortaya çıktığında hemen anında bozulmazlar.

Dağıtık belleğe sahiptirler: Yapay sinir ağlarında bilgi ağa yayılmış durumdadır. Hücrelerin birbirleri ile bağlantılarının değerleri ağın bilgisini gösterir. Tek bir bağlantının bir anlamı yoktur. Daha önce belirtildiği gibi ağın bilgilerinin açıklanamamasının sebeplerinden birisi de budur. Ağın tamamı öğrendiği olayın bütünü karakterize etmektedir. O nedenle bilgiler ağa dağıtılmış durumdadır. Bu ise dağıtık bir belleğin doğmasına neden olmaktadır.

Sadece nümerik bilgiler ile çalışabilmektedirler: Yapay sinir ağları sadece nümerik bilgiler ile çalışırlar. Sembolik ifadeler ile gösterilen bilgilerin nümerik gösterime çevrilmeleri gerekmektedir. Bunun nasıl yapıldığı daha sonra açıklanacaktır. Sembolik bilgilerin nümerik değerler ile ifade edilmesinde bilgilerin yorumlanmasını ve kararların (üretilen çözümlerin) açıklanmasını zorlaştırmaktadır.

Yapay sinir ağlarının çok kullanışlı yönleri olduğu gibi, kullanılması sırasında sistemin içerisinde ne olduğunun bilinmemesi, kararlılık analizleri yapılamaması, uyarılma zorluğu, donanım bağımlı olunması, uygun ağ yapısının deneme yanılma yolu ile belirlenmesi, ağ

parametrelerinin belirlenmesi ve eğitimin ne zaman bitirileceğine karar verilmesinde belirli bir kural olmayışı, ağıın davranışının açıklanamaması ve sadece nümerik bilgilerle çalışabilmesi gibi bazı önemli olumsuzluklar da barındırmaktadır.

Çizelge 3.2 Çeşitli sinir ağı modellerinin zayıf ve kuvvetli yönleri (Bayraktaroğlu, 1996).

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

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

3.5 Kullanım Alanları

Yapay sinir ağları genel olarak, doğrusal olmayan, gürültülü ve hata olasılığı yüksek verilere sahip olunması ve problemin çözümü için herhangi bir matematik modelin olmadığı

durumlarda kullanılmaktadır. Yapay sinir ağlarının başlıca uygulama alanları sınıflandırma, *tahmin* ve modelleme olarak ele alınabilir (Elmas, 2003). Günlük hayatta, finansal konulardan mühendisliğe ve tıp bilimine kadar birçok uygulamadan bahsetmek mümkündür. Bunlardan bazıları şöyle sıralanabilir (Öztemel, 2006):

- Veri madenciliği,
- Optik karakter tanıma ve çek okuma,
- Bankalardan kredi isteyen müracaatları değerlendirme,
- Ürünün pazardaki performansının tahmin etme,
- Kredi kartı hilelerini saptama,
- Zeki araçlar ve robotlar için optimum rota belirleme,
- Güvenlik sistemlerinde konuşma ve parmak izi tanıma,
- Robot hareket mekanizmalarının kontrol edilmesi,
- Mekanik parçaların ömürlerinin ve kırılmalarının tahmin edilmesi,
- Kalite kontrolü,
- İş çizelgeleme ve iş sıralaması,
- İletişim kanallarındaki geçersiz ekoların filtrelenmesi,
- İletişim kanallarındaki trafik yoğunluğunu kontrol etme ve anahtarlama,
- Radar ve sonar sinyalleri sınıflandırma,
- Üretim planlama ve çizelgeleme,
- Kan hücreleri reaksiyonları ve kan analizlerini sınıflandırma,
- Kanserin saptanması ve kalp krizlerinin tedavisi,
- Beyin modellenmesi çalışmaları.

3.6 Klasik Yöntemlerle Olan Benzerlikler

Memmedov ve Eryılmaz yaptıkları çalışmada (2003) , yapay sinir ağlarının belirli sınıf istatistik modeller ile bağlantısını araştırarak, YSA'nın farklı istatistik işlemlerin yerine getirilmesinde etkili rol oynadığını ortaya koymuş; aynı çalışmada, birçok problemin çözümünde her iki sınıf yöntem birlikte kullanılarak, hesaplama sonuçlarının

karşılaştırılmasının daha iyi çözümün bulunması için bir araç olduğu belirtilmiştir. Şen'e göre (2004), her YSA matematikte genel olarak bir fonksiyona karşı gelebileceğinden, girdi değişkenlerine hiçbir şeyden etkilenmediklerini belirtmek için bağımsız değişkenler, çıktılar ise mutlaka girdilere dayandıklarından bağımsız değişkenler ve son olarak da bağların her birine bu iki değişkeni birbirine bağlayan matematik ifadenin ağırlıkları (sabitleri, parametreleri) olarak bakılabilir. Bu yaklaşımla, bazı istatistik terimleri ile YSA terimleri arasındaki ilişki Çizelge 3.2'deki gibi açıklanabilir.


Çizelge 3.3 İstatistik ve YSA terimleri arasındaki ilişki (Memmedov ve Eryılmaz, 2003).

İstatistik terimleri	YSA terimleri
Bağımsız değişken	Giriş
Bağımlı değişken	Hedef
Artık (kalan)	Hata
Tahmin	Öğrenme (eğitim)
Tahmin ölçütü	Hata fonksiyonu
Gözlem	Numune(örnek, eğitim çifti)
Tahminler ana kütle katsayısı	Ağırlıklar
Dönüşüm	Fonksiyonel link
Regresyon	Kontrollü (supervised) öğrenme
Veri indirme	Kontrolsüz (unsupervised) öğrenme

Geçmişte sınıflandırma, kontrol, öngörme, v.b. modellemeleri çok değişik yöntemlerle yapılmıştır. Bunlar arasında matris ve vektör hesaplamaları, regresyon ve korelasyon kavramları, stokastik süreçler ve zaman serisi çözümlemeleri, çoklu regresyon yaklaşımları ve diğerleri gelmektedir. YSA bunların her birisine kısmen de olsa benzer yönler içermektedir.

3.7 Yapay Sinir Ağlarının Sınıflandırılması

Çizelge 3.4 Yapay Sinir Ağlarının Sınıflandırılması (Yarar, 2004).



3.8 Yapay Sinir Ağlarında Öğrenme

Öğrenme, ağıın başlangıçta rastgele olarak atanan ağırlık değerlerinin belirlenmesi işlemidir. Ağ gördüğü her örnek için bu ağırlık değerlerini değiştirir. Bu işlem ağıın doğru ağırlık değerlerine ulaşması, bir başka deyişle, örneklerin temsil ettiği olayla ilgili genelleme yapabilecek duruma gelmesi ile son bulur. Ağırlık değerlerinin değiştirilmesi işlemi, kullanılan öğrenme stratejisine göre değişen ve öğrenme kuralı olarak adlandırılan belli bazı kurallara göre yürütülür (Efe ve Kaynak, 2000; Elmas, 2003; Şen, 2004; Öztemel, 2006).

Yapay sinir ağlarının kullandığı öğrenme stratejileri;

- 1- Eğitici (supervised)
- 2- Eğitici (unsupervised)
- 3- Takviyeli öğrenme (reinforcement training) olarak başlıca üç ana grupta toplanabilir.

Eğitici öğrenmede, her bir örnekleme zamanında giriş uygulandığında sistemin arzu edilen cevabı (y), eğitici tarafından sağlanır. Arzu edilen çıkış (y) ile sinir ağı çıkışı o arasındaki fark hata ölçüsüdür ve ağ parametrelerini güncellemekte kullanılır. Ağırlıkların güncellenmesi süresince eğitici ödüllendirme-cezalandırma şemasını ağa uygulayarak hatayı azaltır. Bu öğrenme modelinde giriş ve çıkış örnekleri kümesi eğitim kümesi olarak adlandırılır. Eğitici öğrenme, ağıın çıktı için istenilen veri değerleri verebilmesi için girdi-çıkış ilişkisini elde edebilmesini sağlayacak bir mekanizma içermektedir. Burada eğitici, ağ sonuçlarının geçerliliğini kontrol eden bir gözlemci olabilir.

Eğiticişiz öğrenmede, eğitimcili öğrenmedeki gibi arzu edilen (y) çıkışları bilinmemektedir. Bu yüzden kesin bir hata bilgisini ağıın davranışını değıştirmekte kullanmak mümkün değıildir. Cevabın doğıruluğı veya yanlışlığı hakkında bilgi sahibi olunmadığı için öğrenme, girişlerin verdiği cevaplar gözlenerek başarıya ulaşılır. Eğitimcişiz öğrenmenin temeli dış müdahale olmaksızın, girdilerin ağı tarafından analiz edilmesi ve bu analiz sonucunda bağlantıların oluşturulmasıdır. Eğitimcişiz öğrenme, girdiler için bazı karakter belirleme uygulamalarında kullanılır. Kendi kendine öğrenme kavramı parlak bir gelişme potansiyeli taşısa da günümüzde tam olarak çalışmamaktadır.

Takviyeli öğrenmede, ağıın davranışının uygun olup olmadığını belirten bir öz yetenek bilgisine ihtiyaç duyulur. Bu bilgiye göre ağırlıklar ayarlanır. Gerçek zamanda öğrenme yöntemi olup deneme-yanılma esasına göre sinir ağı eğitilmektedir. Bu yöntem eğitimcili öğrenme yöntemine benzemekle birlikte, ağı hedef çıktılar yerine, ağıın çıktılarının ne ölçüde doğıru olduğunu belirten bir skor veya derece bildirilir.

1950’li yıllardan günümüze kadar pek çok öğrenme kuralı geliştirilmiş olup bunlardan önemli olanlarına ait örnekler aşağıda verilmiştir (Elmas, 2003):

Hebb kuralı: Eğer bir sinir başka bir sinirden giriş alırsa ve her ikisi de yüksek aktif ise (matematiksel olarak aynı işaretli), sinirler arasındaki boyut kuvvetlendirilir.

Hopfield Kuralı: Eğer istenilen çıkış ve girişin her ikisi de aktif veya her ikisi de durgun ise, bağlantı boyutlarını öğrenme oranı kadar artırılır, aksi halde öğrenme oranı kadar azaltılır.


Kohonen Kuralı: Biyolojik sistemlerdeki öğrenmeden esinlenilmiştir. Sinirler öğrenmek için durum veya ölçülerini güncelleyerek yarışır. En büyük çıkış ile işlenen sinir kazananı ilan eder ve komşularına bağlantı boyutlarını güncellemeleri için izin verilir.

Delta (Windrow-Hoff veya en Küçük Ortalamalar Karesi) Kuralı: Sinirin gerçek çıkışı ile istenilen çıkış değeri arasındaki farkı azaltmak için giriş bağlantı güçlerini sürekli olarak geliştirme fikrine dayanır. Bu kural ağı hatasının karesini en azlamak için bağlantı boyutlarını değıştirir. Hata bir önceki katmana geri çoğaltılır.

3.9 Yapay Sinir Ağlarının Mimarisi


Yapay sinir ağları, sinir ya da düğüm adı verilen çok sayıdaki işlem elemanın bir araya gelmesinden oluşur. YSA mimarileri, sinirler arasındaki bağlantıların yönlerine göre veya ağı içindeki işaretlerin akış yönlerine göre birbirlerinden ayrılmaktadır. Buna göre yapay sinir ağları için ileri beslemeli (feedforward) ve geri beslemeli (feedback/recurrent) ağlar olmak üzere iki temel ağı mimarisi vardır (Elmas,2003).

İleri beslemeli YSA'da, hücreler katmanlar şeklinde düzenlenir ve bir katmandaki hücrelerin çıkışları bir sonraki katmana ağırlıklar üzerinden giriş olarak verilir. Giriş katmanı, dış ortamlardan aldığı bilgileri hiçbir değişikliğe uğratmadan orta (gizli) katmandaki hücelere iletir. Bilgi, orta ve çıkış katmanında işlenerek ağ çıkışı belirlenir. İleri beslemeli 3 katmanlı YSA'nın, orta katmanında yeterli sayıda hücre olmak kaydıyla, herhangi bir sürekli fonksiyonu istenilen doğrulukta yaklaştırabileceği gösterilmiştir. En çok bilinen geriye yayılım öğrenme algoritması, bu tip YSA'ların eğitiminde etkin olarak kullanılmakta ve bazen bu ağlara geriye yayılım ağları da denmektedir. Şekil 3.6'da giriş, orta ve çıkış katmanı olmak üzere 3 katmanlı ileri beslemeli YSA yapısı verilmiştir.



Şekil 3.7 İleri beslemeli üç katmanlı YSA (Öztemel, 2006).

Geri beslemeli YSA'da, en az bir hücrenin çıkışı kendisine ya da diğer hücelere giriş olarak verilir ve genellikle geri besleme bir geciktirme elemanı üzerinden yapılır. Geri besleme, bir katmandaki hücreler arasında olduğu gibi katmanlar arasındaki hücreler arasında da olabilir. Bu yapısı ile geri beslemeli YSA, doğrusal olmayan dinamik bir davranış gösterir. Dolayısıyla, geri beslemenin yapılış şekline göre farklı yapıda ve davranışta geri beslemeli YSA yapıları elde edilebilir. Şekil 3.7'de çıkışlarından giriş katmanına geri beslemeli bir YSA yapısı görülmektedir.



Şekil 3.8 Geri beslemeli YSA (Öztemel, 2006).

Farklı öğrenme stratejileri ve bunların ağı yapısı üzerindeki etkileri YSA'da çeşitliliği sağlamaktadır. Öğrenme stratejilerine göre YSA sınıflara ayrıldığında, danışmanlı öğrenme prensibini kullanan ağ yapılarına perceptron, çok katmanlı perceptron ve geriye yayılım ağı, danışmansız öğrenme stratejisini kullanan ağ yapılarına ise Hopfield ağı, Boltzman makinesi, Hamming ağı, rekabetçi öğrenme ağları ve ART (Adaptif Rezonans Teorisi) ağları örnek gösterilebilir.


3.10. Geri Yayılım Algoritması ve Çok Katmanlı Algılayıcı (ÇKA) Modeli

Bu çalışma içerisinde yapılan analizlerde ağ mimarisi olarak çok katmanlı algılayıcı (ÇKA) modeli kullanıldığından, bu kısımda söz konusu ağ modeli, kullandığı öğrenme algoritması ve çalışma yöntemine yer verilmiştir.

3.10.1 ÇKA öğrenme algoritması

Çok katmanlı algılayıcı ağları eğitici öğrenme stratejisini esas alır. ÇKA ağının öğrenme kuralı en küçük kareler yöntemine dayalı Delta öğrenme kuralının genelleştirilmiş halidir (Öztemel, 2006). Genelleştirilmiş Delta Algoritması (Geriye yayılım algoritması (GY) / backpropagation (BP) olarak da anılır), öğrenme algoritmaları içinde en yaygın biçimde kullanılanıdır. Bu algortmada hata, ağıdaki ağırlıkların bir fonksiyonudur. Hataların kareleri ortalaması dereceli azaltma yöntemi kullanılarak en azlanmaya çalışılır.

Geriye yayılım algoritması iki safhadan oluşmaktadır. *İleriye doğru hesaplamada* ağın çıktısı hesaplanırken, *geriye doğru hesaplamada* ağın ağırlıkları değiştirilir. Bu iki safhada ağın gerçekleştirdiği hesap adımları aşağıda özetlenmiştir (Öztemel, 2006).



Şekil 3.9 Çok katmanlı algılayıcı modeli (Öztemel, 2006).

İleriye doğru hesaplama

- Eğitim setindeki bir örnek girdi katmanından ağa gösterilir. Gelen girdiler herhangi bir değişiklik olmadan ara katmana gönderilir. Bu durumda girdi katmanındaki k . işlem elemanının çıktısı (Şekil 3.8),

$$G_k^i = G_k \quad (3.2)$$

olarak gösterilir.

- Ara katmandaki işlem elemanları, girdi katmanındaki elemanların her birinden gelen bilgileri ağırlıkların etkisi ile alır. Ara katman elemanına gelen net girdi,

$$NET_j^a = \sum_{k=1}^n A_{kj} G_k^i \quad (3.3)$$

ile bulunur.

- Aktivasyon fonksiyonu olarak sigmoid fonksiyonunun kullanılması halinde j . ara katman elemanının çıktısı,

$$G_j^a = \frac{1}{1 + e^{-(NET_j^a + \beta_j^a)}} \quad (3.4)$$

olur. j β ara katmandaki j . elemana bağlanan eşik değer elemanın ağırlığıdır. Bu işlem için daha önce belirtilen aktivasyon fonksiyonlarından birini kullanmak da mümkündür.

Yukarıda sıralanan hesap adımları ara katman ve çıkış katmanının tüm elemanları için gerçekleştirilerek çıktı katmanından çıkan değerler bulunmuş ve böylelikle ileriye doğru hesaplama tamamlanmış olur.

Geriye doğru hesaplama

- Ağın ileriye doğru hesaplaması sonucunda elde edilen çıktılar, ağın beklenen çıktıları ile karşılaştırılarak, bu değerler arasındaki fark bulunur. Bu fark hata olarak değerlendirilir. Ağın bundan sonraki amacı bu hatanın düşürülmesi olduğundan, geriye doğru hesaplamada bu hata değeri ağın bağlantı ağırlıklarına dağıtılır. Çıktı katmanındaki m. işlem elemanında hata Eş. 3.5'deki gibi hesaplanır.

$$E_m = B_m - C_m \quad (3.5)$$

- Tüm çıktı katmanı elemanlarının hatası toplanır. Bazı hata değerlerinin negatif olmasından dolayı, toplamın sıfır olmasını engellemek üzere hata değerlerinin karesi alınarak, sonucun karekökü bulunur.

$$TH = \frac{1}{2} \sum_m E_m^2 \quad (3.6)$$

Çıktı katmanı ile ara katman arasındaki bağlantı ağırlıklarının değiştirilmesi:

- Ara katmanda bulunan j. işlem elemanını çıktı katmanındaki m. İşlem elemanına bağlayan ağırlık değerindeki değişim miktarı ΔA^a ile gösterildiğinde, t. iterasyondaki ağırlık değişimi,

$$\Delta A_{jm}^a(t) = \lambda \delta_m C_j^a + \alpha \Delta A_{jm}^a(t-1) \quad (3.7)$$

olarak bulunur. Eşitlikteki λ öğrenme katsayısını, α momentum katsayısını göstermektedir. m. çıktı elemanının hatasını ifade eden δ_m şu şekilde hesaplanır:

$$\delta_m = f'(NET).E_m \quad (3.8)$$

- Eş. 3.8'deki $f'(NET)$ kullanılan aktivasyon fonksiyonunun türevidir. Aktivasyon fonksiyonu olarak sigmoid fonksiyonu kullanılması halinde, m. çıktı elemanının hatası,

$$\delta_m = C_m(1 - C_m).E_m \quad (3.9)$$

- Ağırlıkların değişim miktarı hesaplandığına göre, t. iterasyonda yeni bağlantı değerleri,

$$A_{jm}^a(t) = A_{jm}^a(t-1) + \Delta A_{jm}^a(t) \quad (3.10)$$

olacaktır.

- Aynı biçimde eşik değer elemanının ağırlıklarını da değiştirmek gerekeceğinden, yine değişim miktarını Eş. 3.11'i kullanarak hesaplamak gerekir. β_c çıktı katmanında bulunan işlem elemanlarının eşik değer ağırlıklarını gösterir. Eşik değer elemanı değeri sabit ve 1'dir.

$$\Delta\beta_m^c(t) = \lambda\delta_m + \alpha\Delta\beta_m^c(t-1) \quad (3.11)$$

Eşik değer elemanının t. iterasyondaki ağırlığı ise,

$$\beta_m^c(t) = \beta_m^c(t-1) + \Delta\beta_m^c(t) \quad (3.12)$$

olarak bulunur.

Ara katman ile girdi katmanı arasındaki bağlantı ağırlıklarının değiştirilmesi:

- Ara katman ile girdi katmanı arasındaki ağırlıkların değişimi ΔA_i ,

$$\Delta A_{kj}^i(t) = \lambda\delta_j^a \zeta_k^i + \alpha\Delta A_{kj}^i(t-1) \quad (3.13)$$

şeklinde hesaplanır. Eş. 3.13'deki δ^a ise,

$$\delta_j^a = f'(NET) \sum_m \delta_m A_{jm}^a \quad (3.14)$$

ile hesaplanır. Yine, aktivasyon fonksiyonu olarak sigmoid fonksiyonu kullanıldığında, hata değeri Eş. 3.15'de gösterildiği gibi bulunur.

$$\delta_j^a = \zeta_j^a (1 - \zeta_j^a) \sum_m \delta_m A_{jm}^a \quad (3.15)$$

- Ağırlıkların yeni değeri,

$$A_{kj}^i(t) = A_{kj}^i(t-1) + \Delta A_{kj}^i(t) \quad (3.16)$$

olacaktır.

- Benzer şekilde, eşik değer elemanının da ağırlık değerinin değiştirilmesi gerekir. Ara katman eşik değer ağırlığı β_a ile gösterilirse,

$$\Delta\beta_j^a(t) = \lambda\delta_j^a + \alpha\Delta\beta_j^a(t-1) \quad (3.17)$$


olarak değişim miktarı hesap edilir. Ağırlıkların t. iterasyondaki yeni değeri ise Eş. 3.18'deki gibi bulunur.

$$\beta_j^a(t) = \beta_j^a(t-1) + \Delta\beta_j^a(t) \quad (3.18)$$

Her iterasyonda ağı yeni örnekler gösterilerek, yukarıda özetlenen ileri ve geri hesaplama adımları gerçekleştirilir ve ağı tüm ağırlıkları değiştirilir.


3.10.2 ÇKA ağına çalışma yöntemi

ÇKA ağlarının çalışması için sırasıyla örneklerin toplanması, ağ topolojisinin belirlenmesi, öğrenme parametrelerinin belirlenmesi, ağı başlangıç değerlerinin atanması ve öğrenme aşamalarının gerçekleştirilmesi gerekir (Şekil 3.10).




Şekil 3.10 ÇKA çalışma yöntemi (Öztemel, 2006).

- *Örneklerin toplanması:* Ağı öğrenmesi istenilen olay için bu olayın daha önce gerçekleşmiş bulunan örnekleri toplanır.
- *Ağ topolojisinin belirlenmesi:* Ağı kaç katmandan oluşacağı ve bu katmanlarda yer alacak işlem elemanı sayısı belirlenir.
- *Öğrenme parametrelerinin belirlenmesi:* Öğrenme ve momentum katsayısı, işlem elemanlarına ait toplama ve aktivasyon fonksiyonları belirlenir.
- *Ağırlıkların başlangıç değerlerinin atanması:* Ağırlıklar girişler ve ara katmanlar için (-0.1, 0.1) arasında rastgele belirlenir. Öğrenme başlangıcında küçük adımlar atılması gerektiğinden, bu aralık küçük tutulmaktadır.
- *Öğrenme:* Örnek vektörü girişe uygulanır. Girişe uygulanan vektör için çıktı değerleri ve ağı ürettiği hata değeri saptanır. Geriye doğru hesap adımları gerçekleştirilerek hata ağı bağlantı ağırlıklarına yayılır. Öğrenme sürecinde çok sayıda iterasyon gerektirir ve ağ çok yavaş öğrenir. Ancak ağ, seçilen başlangıç değerlerine de bağlı olarak yerel minimuma az düşer.



Şekil 3.11 Hata uzayında öğrenmenin gösterilmesi (Öztemel, 2006).

Şekil 3.11’de verilen hata uzayında, ağırlık ele alınan problem için en az hata anlamına gelen X^* değerine ulaşması beklenmektedir. Ancak en az hatayı veren ağırlık vektörüne ulaşmak her zaman mümkün olamadığı gibi çoğu kez hata grafiği Şekil 3.12’de gösterildiği gibi karmaşık olacaktır. Burada, ağırlık ulaştığı ve kabul edilebilir durumdaki en düşük hata X^* ile gösterilmiştir.



Şekil 3.12 Öğrenme sırasında oluşan yerel çözümler (Öztemel, 2006).

Yapay sinir ağlarında birden fazla çözüm olabilir ve en iyi çözümün hangisi olduğunu bilmek çoğu zaman mümkün değildir. Bu nedenle yapay sinir ağlarının en iyi çözümü bulduğu iddia edilemez.

En iyi çözüm bulamamanın sebepleri şunlar olabilir.

- Problem eğitilirken bulunan örnekler problem uzayını %100 temsil etmeyebilir.

- Oluşturulan yapay sinir ağı için doğru parametreler seçilmemiş olabilir.
- Ağın ağırlıkları başlangıçta tam istenildiği şekilde belirlenmemiş olabilir.
- Ağın topolojisi yetersiz seçilmiş olabilir.

Bazı durumlarda da ağın takıldığı yerel çözüm tolerans değerinin üstünde kalabilir. Bu durumda ağın olayı öğrenmesi için bazı değişiklikler yapılarak yeniden eğitilmesi gerekir. Başlıca yapılabilecek değişiklikler :

- Başka başlangıç değerlerinin kullanılması
- Topolojide değişikliklerin yapılması (ara katman sayısının artırılması, proses elemanı sayısının artırılması veya azaltılması gibi)
- Parametrelerde değişiklikler yapılması (fonksiyonların başka seçilmesi, öğrenme ve momentum katsayılarının değiştirilmesi gibi)
- Problemin gösterimi ve örneklerin formülasyonunun değiştirilerek yeni örnek setinin oluşturulması
- Öğrenme setindeki örneklerin sayısının artırılması veya azaltılması
- Öğrenme sürecinde örneklerin ağına gösterilmesi

Problemin X_0 , X_1 , X_2 ve X_3 olası çözümleri “yerel çözümler” olarak ifade edilir. X_0 ve X_2 kabul edilebilir hatanın (E_t) üzerinde değerler aldıklarından bu çözümler kabul edilemez. Ancak E_t değerinin altında bulunan X_1 ve X_3 çözümleri kabul edilebilir seviyededir.

ÇKA ağlarının yukarıda bahsedilen yerel çözümlere takılmaması için, bir önceki iterasyondaki değişimin belirli bir oranda yeni değişim miktarına eklenmesi gerekir. Bu oran momentum katsayısı olarak adlandırılır. Öğrenme katsayısı ise ağırlıkların değişim miktarını belirler.

Öğrenme sürecinde, ağı ağırlıklarının ne zaman değiştirileceğine problemin yapısına ve kullanılan öğrenme algoritmasına göre karar verilir. Ağırlıkların değiştirilmesi için genellikle üç yöntem uygulanmaktadır:

1. Her bir örnek ağına gösterildikten sonra hata hesaplanarak ağına dağıtılır (pattern based).
2. Belirli sayıda örnek gösterildikten sonra oluşan hatalar toplanarak ağına dağıtılır (batch based).
3. Bütün örnekler ağına gösterildikten sonra oluşan hatalar toplanarak ağına dağıtılır (epoch based).

Ağın eğitilmesi sürecinde ”öğrenmenin” ne kadar süreceğini, bir başka deyişle, kaç iterasyonda tamamlanacağını kestirmek oldukça güçtür. Problemin yapısına göre öğrenme süresi ve iterasyon sayısı değişmektedir. Öğrenmenin tamamlanıp tamamlanmadığını belirlemek için ağın hatasını gösteren grafikler incelenerek, hatanın belirli bir seviyenin altına düşmediği nokta belirlenebilir. Bu nokta ağın daha fazla öğrenemeyeceğini gösterir. Öğrenmenin tamamlanması için bir başka yol ise, ağın belirli bir iterasyon sonunda durdurulmasıdır.

3.10.3 Ağın performansının belirlenmesi

Bir yapay sinir ağının performansı daha önce hiç görmediği örneklerle ürettiği sonuçların doğruluğu ile belirlenir. Bunun için ağı eğitmek üzere toplanan örneklerden bir kısmı test için ayrılır. Bazı durumlarda ağı eğitimi sırasında verilen tüm örneklerle doğru cevap üretse dahi test setindeki örneklerle doğru cevap veremeyebilir. Performans ölçüsü olarak Eş. 3.19 kullanılabilir.

$$Performans = \frac{T}{T_t} \times 100 \quad (3.19)$$

Eş. 3.19’da T , test setinde doğru cevaplandırılan örnek sayısını, T_t ise test setine bulunan toplam örnek sayısını gösterir.

3.10.4 Girdi ve çıktıların ölçeklendirilmesi

Ele alınan problemin özelliklerini en iyi yansıtan örnekler belirlenirken, bunlardan bazılarının farklı ölçek kullanan ortamlardan seçildiği durumlarda, tüm örneklerin aynı ölçekte toplanması gerekir. Verinin normalize edilmesi olarak bilinen bu işlem için araştırmacı değişik yöntemler kullanabilir. Diğer taraftan ağı ölçeklendirilmiş (normalize edilmiş) girdileri kullanacağından, dış dünyaya ileteceği çıktılar da aynı ölçek üzerinde yer alacaktır. Ağın çıktılarının dış dünya da anlaşılabilir olmasını sağlamak amacıyla girdi setine uygulanan ölçeklendirme işlemi tersine çevrilerek, çıktılara uygulanır.

3.11 Yapay Sinir Ağları Tarihçesi

YSA’lar ile ilgili ilk çalışmalar 20.yy’ın ilk yarısında başlamış ve günümüze kadar büyük bir hızla devam etmiştir. Bu çalışmaları 1970 öncesi ve sonrası diye iki kısma ayırmak mümkündür. Çünkü 1970 yılları YSA için bir dönüm noktasını teşkil etmiş daha önce aşılması imkânsız görünen pek çok problem bu dönemlerde aşılmıştır.

İlk yapay sinir ağı modeli 1943 yılında, bir sinir hekimi olan Warren McCulloch ile bir matematikçi olan Walter Pitts tarafından tasarlanmıştır. McCulloch ve Pitts, insan beyninin hesaplama yeteneğinden esinlenerek, elektrik devreleriyle basit bir sinir ağı modellemişlerdir. Çünkü insanın sinir hücreleri de aradaki kimyasal maddeler sayesinde elektrik akımlarını iktrek öğrenmeyi gerçekleştirmektedir.

1948 yılında Wiener, "Cybernetics" isimi kitabında, sinirlerin çalışması ve davranış özelliklerine değinmiş, 1949 yılında ise Hebb "Organization of Behavior" adlı eserinde öğrenme ile ilgili temel teoriyi ele almıştır.

Hebb kitabında öğrenebilen ve uyum sağlayabilen sinir ağları modeli için temel oluşturacak "Hebb kuralı"nı ortaya koymuştur. Hebb kuralı; sinir ağının bağlantı sayısı değiştirilirse, öğrenme kapasitesinin değiştirilebileceğini ön görmekteydi.

1957 yılında Frank Rosenblatt'ın Perceptron'u geliştirmesinden sonra, YSA'lar ile ilgili çalışmalar hız kazanmıştır. Perceptron; beyin işlevlerini modelleyebilmek amacıyla yapılan çalışmalar neticesinde ortaya çıkan tek katmanlı eğitilebilen ve tek çıkışa sahip bir ağ modeli olarak tanımlanmıştır (Elmas, 2003).

1959 yılında Bernard Widrow ve Marcian Hoff (Stanford Üniversitesi) tarafından geliştirilen ADALINE (Adaptive Linear Neuron) modeli YSA'ların mühendislik uygulamaları için başlangıç kabul edilmiştir. Bu model Rosenblatt'ın Perceptron'una benzemekle birlikte, öğrenme algoritması daha gelişmiştir. Bu model uzun mesafelerdeki telefon hatlarındaki yankıları ve gürültüleri yok eden bir adaptif filtre olarak kullanılmış ve gerçek dünya problemlerine uygulanan ilk YSA olma özelliğini kazanmıştır. Bu yöntem günümüzde de aynı amaçla kullanılmaktadır.

1960'ların sonlarına doğru YSA çalışmaları durma noktasına gelmiştir. Buna en önemli etki; Minsky ve Pappert tarafından yazılan Perceptrons adlı kitaptır. Burada YSA'ların doğrusal olmayan problemleri çözemediği meşhur XOR* (eXclusive OR) problemi ile ispatlanmış ve YSA çalışmaları bıçak gibi kesilmiştir.

Tüm bunlara rağmen Anderson, Amari, Cooper, Fukushima, Grossberg, Kohonen, Hopfield gibi bilim adamları çalışmalarını sürdürmüşler, 1972 de Kohonen ve Anderson Associative Memory konusunda benzer çalışmalar yayınlamışlardır. Kohonen daha sonra 1982 yılında "Kendi Kendine Öğrenme Nitelikli Haritalar" (Self Organizing Feature Maps - SOM)

* Ayrıcalıklı VEYA / YA DA

konusundaki çalışmasını yayınlamıştır. 1960'ların sonlarına doğru Grosberg Carpenter ile birlikte Adaptif Rezonans Teorisini (ART) geliştirmiştir.

1970'lerin sonlarına doğru Fukushima, NEOCOGNITRON modelini tanıtmıştır. Bu model şekil ve örüntü tanıma amaçlı geliştirilmiştir.

1982-1984 yıllarında Hopfield tarafından yayınlanan çalışmalar, YSA'ların geliştirilebileceği ve çözümü zor problemlere çözüm üretebileceğini göstermiştir. Bunlara geleneksel gezgin satıcı problemi örnek olarak gösterilebilir. Bu çalışmaların neticesi Hinton ve arkadaşlarının geliştirdiği Boltzman Makinesi'nin doğmasına yol açmıştır.

1988 yılında, Broomhead ve Lowe radyal tabanlı fonksiyonlar modelini (Radial Basis Functions - RBF) geliştirmişler ve özellikle filtreleme konusunda başarılı sonuçlar elde etmişlerdir. Daha sonra Spect, bu ağların daha gelişmiş şekli olan Probabilistik ağlar (PNN) ve Genel Regresyon Ağlarını (GRNN) geliştirmiştir (Öztemel, 2003).

Bu tarihten günümüze kadar sayısız çalışma ve uygulama geliştirilmiştir, bu çalışmaların temel noktalarının kronolojisi aşağıdaki gibidir.

1890- insan beyninin yapısı ve fonksiyonları ile ilgili ilk yayının yazılması

1911- insan beyninin sinir hücrelerinden oluştuğu fikrinin benimsenmesi

1943- yapay sinir hücrelerine dayanan hesaplama teorisinin ortaya atılması ve eşik değerli mantıksal devrelerin geliştirilmesi

1949- öğrenme prosedürünün bilgisayarlar tarafından gerçekleştirilecek şekilde geliştirilmesi

1956 - 1962 ADALINE ve Widrow - Hoff öğrenme algoritmasının geliştirilmesi

1957 - 1962 Perceptron'un geliştirilmesi

1965- ilk makine öğrenmesi kitabının yayınlanması

1967 - 1969 bazı gelişmiş öğrenme algoritmalarının geliştirilmesi (Grasberg vs.)

1969- tek katmanlı algılayıcıların yetersizliklerinin ispatlanması

1969 - 1972 doğrusal ilişkilendiricilerin geliştirilmesi

1972- korelasyon matris belleğinin geliştirilmesi

1974- geriye yayılım modelinin geliştirilmesi

1978- ART modelinin geliştirilmesi

1982- çok katmanlı algılayıcıların geliştirilmesi

1984- Boltzman Makinası'nın geliştirilmesi

1988- RBF modelinin geliştirilmesi

1991- GRNN modelinin geliştirilmesi (Öztemel, 2003; Haykin,1994; Efe, 2004).

4. METODOLOJİ VE VERİ SEÇİMİ

4.1 Metodoloji Seçimi

Hill vd.(1996), gelenekçi istatistiksel zaman serileri yöntemlerinin zaman zaman bağımlı ve bağımsız değişkenlere bağlı fonksiyonel formlarını yanlış değerlendirdiklerini vurgulamışlardır. Bu yanlış değerlendirilen ilişkiler modelin inşasında hatalara sebebiyet verebilmektedir. Bu gelenekçi metodlar veri dönüşümü esnasında başarısızlıklara da sebep olabilmektedirler (Gutierrez vd., 2007) .Verideki bu aykırı değerlerin varlığı tahminlerin modeldeki objektif etkisini azaltacaktır (Iman ve Conovar, 1983). Bu modeller, bir önceki veri üzerinden tekrar iyileştirilmelidir. Ve hatta gelenekçi zaman serisi metodları doğrusal olmayan durumlar için başarısız olabilmektedirler. Yapay sinir ağları (YSA) ya da basitçe sinir ağları (SA) modelleri, işte bu pürüzleri aşabilecek, tolere edebilecek bir mantıksal yapıya sahiptir. Sinir ağları, doğrusal yada olmayan kalıpları, veriye yeni yapısında var olan varlıkları ekleyerek tolere edebilme yeteneğine sahiptir. esneklik ve doğrusal olmama sinir ağlarının en güçlü özellikleridir (Weiland ve Leighton, 1988). Yapay sinir ağları ayrıca bağımlı ve bağımsız değişkenler arasındaki ilişkiyi öğrenme yeteneğine de sahiptir (Gutierrez vd., 2007) ki bu metodun bu çalışmadaki uygulamanın başarısını doğrudan etkilediği söylenebilir.

Perakende sektörü ekonomik krizlerden, dalgalanmalardan, mevsimlerden, özel günlerden, hasatın bolluğu ya da azlığından, rekabet şartlarının ağırlığı yada sektördeki tekelliğinden, ithalatın yapılabilirliğinden, ülke içindeki insanların mutluluğu ve mutsuzluğundan dolayı ya da doğrudan etkilenen açık ve saklı onlarca parametresi bulunan bir sektördür. Bu sebeple bu sektör için yapılacak ileriye dönük tüm bütçeleme çalışmaları, satış planları, istihdam planları, stok bulundurma miktarları, emniyet stoğu seviyesi belirleme süreçleri, bölgesel, ulusal yayılım politikaları, değişik formatlarda çalışma eğilimleri için yapılacak tüm stratejik planlamaları sektöre uğratabilecek iç ve dış etkenleri göz önünde bulundurmak bir zorunluluktur.

Yapay sinir ağlarının önemli bir özelliği ise genelleme yapabilmesidir; bu sayede daha önce karşılaşmadığı örnekler karşısında bocalamayarak doğru ya da doğruya yakın sonuçlar üretebilmektedir. YSA, ilgilendiği problemdeki değişikliklere göre ağırlıklarını ayarlar. Yani, belirli bir problemi çözmek amacıyla eğitilen YSA, problemdeki değişimlere göre tekrar eğitilebilir, değişimler devamlı ise gerçek zamanda da eğitime devam edilebilir. Bu özelliği ile de yapay sinir ağları (YSA) bu kadar dinamik bir bilgi ve işlem akışı yaşanan bu sektör için oldukça avantajlı olmaktadır.

Sektörü etkileyen tüm parametreler göz önünde bulundurulduğunda -ki tümünü saymak imkansızdır- bu parametrelerin bazıları hesaba katılmak için oldukça olağanüstü durumlar iken bazıları ise sadece rakamlarla ifade edilemez. Bu parametrelerin hesaba katılabilmesi için görülmesi ve yaşanması gerekebilir. Bu sebeple metodolojiyi seçerken sadece rakamların baz alındığı bir yöntem seçmektense zaman zaman rakamlar olmadan da yorumlanabilir ve hesaba katılabilir parametreleri göz önünde bulundurabilecek, yaşanmış olay ve dönüm noktalarını atlamayacak, tecrübenin esas alındığı bir yöntem seçme eğilimi gösterdim. Sadece rakamlarla yaşanmışlıkların ifade edildiği bir dünya gerçekçilikten daha uzak ve pratikte uygulanabilirliği tecrübenin esas olduğu bir yöntemle göre daha başarısız çağrışımı yapmaktadır. Bunun böyle olduğu gerçeği, çalışma hayatında da üzerine basılarak belirtilebilecek bir öneme sahiptir. Bu sebeple çalışmada kullanmak için sadece rakamları değil sözle ifade edilebilen başka parametreleri de hesaba katabilecek bir yöntem olan “Yapay Sinir Ağları” seçilmiştir. Sözle ifade edilebilen parametrelerin ne olduğu ve niçin bu kadar önemli olduğu ileriki bölümlerde sonuçlarla birlikte ilişkilendirilecektir.

4.2 Veri Seçimi

Bir çok çalışmada vurgulandığı üzere yapay sinir ağlarının doğrusal olmayan veri kümeleri için yapılan tahminlerde oldukça etkili olduğu vurgulanmıştır. Yöntemin başarılılığını göstermek amacıyla seçilecek örnekte bu sebeple olması gereken özellikler konusunda hassasiyet gösterilmiştir.


Birkaç veri seçeneği arasında yapılan kıyaslama çalışmasında hem mevsimsellikten etkilenen, hem doğrusal olmayan, hem farklı dönem, zaman ya da hatta günlere denk gelen pik noktalarına sahip, olağan hayat şartlarıyla değil tahminin yapılacağı uzay için özel şartlar tanımlanabilecek, öğrenmenin gerçekleşmesi için geçmiş veriye kolay ulaşılabilir, muadil ürün veya ürün grupları bulunan, muadilleri ile zaman zaman ciddi rekabetlere girebilen, hem sözel hem de sayısal parametrelere bağlı değişkenleri bulunan örnek küme belirlendi. Veri seçiminde perakende sektörünün önemli kuruluşlarından bir şirketin, hava durumu, mevsimler ve günün hafta içi yada hafta sonu olmasıyla bile satışlarının etkilenebildiği, müşteri potansiyeli yüksek bir mağazasının yine satışlarının sıcaklık, mevsim, özel günler ve promosyonlarla etkilendiği önemli bir tüketim maddesi olan bir kolalı içecek seçilmiştir. Elemesi yapılan veri kümeleri ise satışlarındaki dalgalanmaların neredeyse sadece promosyonla etkilendiği doğrusala yakın bir grafik çizen sıvı bulaşık deterjanı; ve satışları promosyon ve mevsimle doğrusal olarak artan bir ürün grubu olan pet şişe kaynak suları olmuştur. Bu çerçevede çalışmada kullanılan veri için elenen örnek kümelerin bu özelliklerine

ek olarak özel günlerde satışlarının onlarca katına çıkabilmesi ve doğrusallığı aykırı bir şekilde bozması (Şekil 4.1, Şekil 4.2, Şekil 4.3), yapay sinir ağlarının bu özelliğini vurgulamak için önemli bir kaynak olmuştur. Grafiklerden de anlaşılacağı gibi, dönemlik satış artışları yaşanabildiği gibi, ani yükselişler de gözlemlenmektedir. Şekil 4.3'te de görüldüğü gibi satış grafiklerinde “peak point*” denilen satışların ani artış gösterdiği zamanlar ve daha az keskin artışların yaşandığı dönemler açıkça görülmektedir. İşte yapay sinir ağlarıyla yapılan çalışma bu artışların da sebeplerine dikkat çekecektir. Böylece veriden yararlanarak sonuç, sonuçtan yararlanarak da veriye ulaşılmış olunacaktır.


4.3 Verinin Düzenlenmesi

Verilerin teminin ardından satışların tarihleri, haftanın hangi gününe denk geldiği, hafta içi ve hafta sonu olması, herhangi bir özel güne denk gelip gelmemesi, mevsim bilgileri eklenmiştir. Ürünün kendisi ve ikame ürünler için de farklı adlarda promosyon bilgilerinin düzenlenmesinin ardından bunlar her bir ürün için tek hale getirilmiştir. Çünkü sistemde nümerik olmayan veriler çevrilirken veriler sütunlara ayrılmaktadır. Bu da sütunları yetersiz kalacağı için promosyon bilgileri sadeleştirilmiştir. Satış fiyatları şirket tarafından paylaşılması istenmeyen veriler olduğu için tamamen çıkarılmıştır. Satış rakamlarında da şirketin gizlilik politikası sebebiyle değişiklik yapılmıştır. Veri ile ilgili ayrıntı Ek.1'de yer almaktadır.


* Tepe noktası



Şekil 4.1 2008 yılı satış grafiği.



Şekil 4.2 2009 yılı satış grafiği.



Şekil 4.3 2008-2009 yılları satış grafiği.

5. UYGULAMA

Modern programlama platformları sayesinde her şey çok daha kolay hale gelmiştir. Web ve mobil iletişimin de yaygınlaşması ile kavramlarda meydana gelen değişimler sonucunda bu konulardaki birçok işleme destek verecek şekilde Java ve .NET platformları ortaya çıkmıştır. .NET dilleri ve Java, Pascal, C ve C++ gibi dillerin eksikliklerini de giderecek ve verimlerini artıracak şekilde tasarlanmışlardır (Deitel, 2002).

Bunların yanı sıra hazırlanan paket programlar kullanım kolaylığı ve daha anlaşılabilir olmaları, ara yüz destekleri sayesinde modellemeyi daha anlaşılır ve basit hale getirmesi, programlama dillerini etkin kullanamayanlar için önemli bir araç olmaları sebebiyle oldukça tercih edilen bir başka yapay sinir ağı modelleme araçları olarak karşımıza çıkmaktadır. NeuroXL Predictor, NeuroSolutions, MATLAB Neuro Networks Tool Box, Java Neural Networks, EasyNNplus, NNUGA (Neural Network Using genetic Algorithm), Statistica Automated Neural Networks (SANN) gibi bu paket programlara örnekler çoğaltılabilir.

Yapılan araştırmalar sonucu oluşturulması amaçlanan ve analizi yapılan veriler için NeuroSolutions programının uygun olduğu kararına varılmıştır çünkü programın sağladığı bir avantaj da verilerin normalizasyonunu yapmada kolaylık sağlaması olmuştur.

NeuroSolutions programının herhangi bir yapay sinir ağı oluşturabilmek için dört ayrı yöntem sunmaktadır. “NeuralExpert”, “NeuroBuilder”, “pre-recorded macro” ve “boş bir breadbord ile model oluşturma”. Çalışmada daha çok ileri seviye kullanıcılara hitap eden NeuroBuilder seçilmiştir.

The NeuralBuilder ileri seviye kullanıcıları hedef almaktadır. Nöral ağ tasarım işlemi sırasında tutarlı adımlar temsil eden bir dizi panel sunar. Her bir panelde seçimler yapar ve gerektiği yerde farklı parametreler girilir. NeuralExpert’te olduğu gibi problem türü kaynaklı sorular sormak yerine, NeuralBuilder sizin belirli nöral modele (topoloji) göre nöral ağı tayin edilmesine izin verir.


Çizelge 5.1 Ağ sembolleri.

Simge	Ad	Tanım	Kullanım amacı
	Axon	Kimlik iletim işlevli PE(işlem elementi) katmanı	Girdi katmanında Dosya bileşeni için yer tutucu olarak hareket edebilir, ya da çizgisel bir çıktı katmanı olarak.

	TanhAxon	Hiperbolik iletim işlevli PE'ler katmanı(çıkış aralığı -1'den 1'e)	Gizli veya çıktı katmanını olarak kullanılır.
	FullSynapse	Tam matriks çarpma	İki akson katmanını bağlar.
	L2Criterion	Kare hata kriteri.	Çıkış ve istenilen sinyal arasındaki hatayı hesaplar, ve geri yayılım ağına geçirir/verir.
	BackAxon	Kimlik iletim işlevli PE(işlem elementi) katmanı	Geri yayılım ağına kullanım için ileri Akson'a "çift" ekler.
	BackTanhAxon	TanhAxon'un türevi olan iletim işlevli PEler katmanı.	Geri yayılım ağına kullanım için ileri TanhAkson'a "çift" ekler.
	BackFullSynapse	Geri tam matriks çarpma	Geri yayılım ağına kullanım için ileri FullSynapse'a "çift" ekler.
	BackCriteriaControl	Geri yayılım ağına olan Girdi.	Geri yayılım ağına kullanım için Criterion'a ekler. Criterion'dan hata alır.
	Momentum	Momentumlu değişim ölçüsü araması	Ağırlıkları günceller. Momentum, ağırlık değişimi düzenli olarak aynı yöndeysel etkin öğrenim oranını artırır.
	StaticControl	Statik ileri denetçisi.	Ağın ileri aktivasyon evresini denetler.
	BackStaticControl	Statik geri yayılım denetçisi	Ağın geri aktivasyon evresini denetler.
	File	Dosya girdisi	Ağ girdisi ve dosyadan istenilen veri için.
	ThresholdTransmitter	Eşiklenmiş verici	Bir bileşeni bir diğerinin değerlerine göre kontrol etmek için.


	BarChart	Bar çizelgesi soruşturması	Veri barını grafik olarak gösterir.
	DataGraph	Grafik soruşturma	Verileri zamana karşı gösterir
	MatrixViewer	Nümerik soruşturma	Nümerik değerleri o an içerisinde gösterir.
	DataWriter	Nümerik soruşturma	Nümerik değerleri zaman boyunca gösterir. Ayrıca dosyaya veri kaydedilmesine izin verir.

Uygulamadaki veriler düzenlenmiş olarak excel dosyasına kaydedilir. Neurosolutions programında NSExcel modülü çalıştırılır (Şekil 5.1).



Şekil 5.1 NS Excel modülü çalıştırılır.

Excel dosyasına eklentiler kısmına NeuroSolutions Toolbox'ı yerleştir (Şekil 5.2).



Şekil 5.2 Eklentiler kısmında Neurosolutions.

Veri kümesinde parametre olarak belirlenen mevsim, ay, gün, haftanın günü, özel günler, satış tahmini yapılacak olan ürünün muadil ürünleri ve kendisinin promosyon bilgisi ve hem muadillerin geçmiş satışları ve çıktı olarak kabul edilen ürünün kendi satış miktarları tabloda yer almaktadır (Şekil 5.3).

	(S)Y	(S)M	(S)D	(S)GÜN	(S)MEVSE	(S)ÖZEL GÜNLER	(S)COCA-COLA 1 LITRE PROMOSYON	(S)PEPSİ COLA 2.5 LT PROMOSYON	(S)COCA-COLA 2.5 L. PROMOSYON	COCA-COLA 1 LITRE Satış miktarı	PEPSİ COLA 2.5 LT Satış miktarı	COCA-COLA 2.5 L. Satış miktarı
56	2008	12	20	Saturday	KIS					44	12	129
57	2008	12	21	Sunday	KIS					37	11	95
58	2008	12	22	Monday	KIS					39	5	82
59	2008	12	23	Tuesday	KIS					40	4	106
60	2008	12	24	Wednesday	KIS			COCA COLA 2.5 PROMOSYON		38	7	109
61	2008	12	25	Thursday	KIS			COCA COLA 2.5 PROMOSYON		37	4	633
62	2008	12	26	Friday	KIS			COCA COLA 2.5 PROMOSYON		37	0	504
63	2008	12	27	Saturday	KIS	SUKRAN GUNU		COCA COLA 2.5 PROMOSYON		57	3	4169
64	2008	12	28	Sunday	KIS			COCA COLA 2.5 PROMOSYON		56	4	4038
65	2008	12	29	Monday	KIS			COCA COLA 2.5 PROMOSYON		44	8	197
66	2008	12	30	Tuesday	KIS					115	18	511
67	2008	12	31	Wednesday	KIS	YILBASI				215	49	974
68	2009	1	1	Thursday	KIS					49	6	80
69	2009	1	2	Friday	KIS					51	1	79
70	2009	1	3	Saturday	KIS					113	4	135
71	2009	1	4	Sunday	KIS					74	7	89


Şekil 5.3 Modelin parametreleri.

Neurosolutions'ın önemli bir özelliğinin sembolik girdilerin normalizasyonunu kendisinin yapması olduğundan bahsedilmiştir. Bu sebeple öncelikle rakamsal olarak ifadesi bulunmayan ya da rakamsal ifadeyle belirtilen fakat sembolik değerleri bulunan girdiler için eklentiler kısmında bu ver sütunları “Sembol” olarak işaretlenmiştir (Şekil 5.4).

	(S)Y	(S)M	(S)D	(S)GÜN	(S)MEVSE	(S)ÖZEL GÜNLER	(S)COCA-COLA 1 LITRE PROMOSYON	(S)PEPSİ COLA 2.5 LT PROMOSYON	(S)COCA-COLA 2.5 L. PROMOSYON	COCA-COLA 1 LITRE Satış miktarı	PEPSİ COLA 2.5 LT Satış miktarı	COCA-COLA 2.5 L. Satış miktarı
56	2008	12	20	Saturday	KIS					44	12	129
57	2008	12	21	Sunday	KIS					37	11	95
58	2008	12	22	Monday	KIS					39	5	82
59	2008	12	23	Tuesday	KIS					40	4	106
60	2008	12	24	Wednesday	KIS			COCA COLA 2.5 PROMOSYON		38	7	109
61	2008	12	25	Thursday	KIS			COCA COLA 2.5 PROMOSYON		37	4	633
62	2008	12	26	Friday	KIS			COCA COLA 2.5 PROMOSYON		37	0	504
63	2008	12	27	Saturday	KIS	SUKRAN GUNU		COCA COLA 2.5 PROMOSYON		57	3	4169
64	2008	12	28	Sunday	KIS			COCA COLA 2.5 PROMOSYON		56	4	4038
65	2008	12	29	Monday	KIS			COCA COLA 2.5 PROMOSYON		44	8	197
66	2008	12	30	Tuesday	KIS					115	18	511
67	2008	12	31	Wednesday	KIS	YILBASI				215	49	974
68	2009	1	1	Thursday	KIS					49	6	80
69	2009	1	2	Friday	KIS					51	1	79
70	2009	1	3	Saturday	KIS					113	4	135
71	2009	1	4	Sunday	KIS					74	7	89


Şekil 5.4 Sembollerin işaretlenmesi.

Sembol sütunlarının belirlenmesinin ardından girdi sütunları işaretlenir (Şekil 5.5). Sembol olarak işaretlenen sütunlar da aslında girdi verilerini oluşturduğu için bu işaretleme işlemine onlar da dahil edilir.




Şekil 5.5 Girdi parametrelerinin belirlenmesi.

Modeldeki girdilere göre öğrenmesi gerçekleştirilecek olan veri için geçmiş örneklerde elde edilen çıktılar da işaretlenir (Şekil 5.6).




Şekil 5.6 Çıktı sütununun işaretlenmesi.

Bundan sonraki aşama en önemli kısım olan eğitim verilerinin işaretlenmesidir (Şekil 5.7). İşaretlenen bu satırlarla ağ öğrenmesini gerçekleştirecek ve bu öğrenmenin ışığında tahminler yapacaktır.




Şekil 5.7 Eğitim satırlarının işaretlenmesi.

Tahmin edilmesi istenen durumlar için girdi parametreleri bulunmak durumundadır, bu sebeple istenilen şartlarda nasıl bir satış beklendiğini tahminlemek amacıyla şartların yer aldığı fakat çıktı kısmının modelin eğitiminden sonra sistem tarafından üretilen verilerle doldurulacağı satırlar da üretim satırları olarak işaretlenir (Şekil 5.8).




Şekil 5.8 Üretim satırlarının işaretlenmesi.

Tüm işaretlemelerin yapılmasının ardından Yeni bir ağ oluşturmak için “New Custom Network” sekmesi işaretlenir (Şekil 5.9).



Şekil 5.9 Ağın oluşturulması.


NeuroBuilder bu aşamadan sonra devreye girmektedir. Bu kısımda en sık kullanılan ağ tipleri yer almaktadır (Şekil 5.10) ve yapay sinir ağlarının doğası gereği tüm bu ağlar üzerinde denemeler yapmak ve en az hatalı sonucu bulmak önem taşımaktadır.



Şekil 5.10 NeuroBuilder ve ağ çeşitleri.

5.1 Multilayer Perceptron (Çok Katmanlı Algılayıcı)


Çok Katmanlı Algılayıcılar (MLP), tipik olarak statik geri yayılma ile eğitilen, katmanlandırılmış ileri besleme ağlarıdır. Bu ağlar, statik model sınıflandırması gerektiren sayısız uygulama içinde yollarını bulmuşlardır. Temel avantajları, kullanımlarının kolay olması ve bütün girdi/çıkış haritalarına yaklaşabilmeleridir. Kilit dezavantajları ise yavaş eğitilmeleri ve çok fazla eğitim verisine ihtiyaç duymalarıdır (Tipik olarak ağ ağırlıklarının üç katı kadar daha fazla eğitim örneği).



Şekil 5.11 MLP ağının programdaki görüntüsü.

5.2 Generalized Feed Forward (Genelleştirilmiş İleri Besleme)


Genelleştirilmiş İleri Besleme ağları, MLP'nin bağlantılarının bir, iki ya da daha fazla kademe atlama yapabildiği bir genellemesidir. Teoride MLP, genelleştirilmiş ileri besleme ağının çözebileceği tüm problemleri çözebilir. Yine de pratikte genelleştirilmiş ileri besleme ağları problemi genelde daha etkili şekilde çözer. Bunun klasik bir örneği, iki spiral (helezon) problemidir. Problemi tanımlamadan, bu, standart bir MLP'nin aynı sayıda işlem ögesi içeren genelleştirilmiş ileri besleme ağından yüzlerce kat daha fazla eğitim epoch'u gerektirdiğini söylemek için yeterlidir.



Şekil 5.12 Generalised Feedforward ağının programdaki görüntüsü.

5.3 Modular Neural Networks (Modüler Sinir Ağları)


Modüler ileri beslemeli ağlar MLP'un özel bir sınıfıdır. Bu ağlar, çeşitli paralel MLP'ler kullanarak girdilerini yönlendirirler ve daha sonra sonuçları tekrar kombine ederler. Bu, topoloji içerisinde fonksiyonun her bir alt modül içinde uzmanlaşmasını besleyecek bir yapı oluşturmaya yönelir. MLP'un tam aksine, modüler ağlar katmanları arasında tam anlamda bir bağlantıya sahip değildirler. Bu nedenle, aynı boyutlu bir ağ için daha az sayıda ağırlık gereklidir. (örneğin aynı sayıda PE - Processing Element - Süreç Ögesi). Bu eğitim sürelerini hızlandırmaya ve gerekli olan eğitim örneklerinin sayısını azaltmaya yönelir. Bir MLP'u modüllere bölmenin birçok yolu vardır. Veri üzerine kurulu modüler topolojinin en iyi şekilde nasıl tasarlanacağı net değildir. Her modülün eğitimini verinin sıradışı bir kısmı üzerinde uzmanlaştıracağının bir garantisi yoktur.



Şekil 5.13 Modüler sinir ağının programdaki görüntüsü.

5.4 Jordan And Elman Network (Jordan Ve Elman Ağı)


Jordan ve Elman ağları, geçmiş olayları hatırlayan süreç ögeleri olan kaynak üniteleriyle çok katmanlı algılayıcıyı genişletirler. Kaynak üniteleri ağa veriden geçici bilgi çıkarma yeteneği sağlar. Jordan ağı ağın çıktısını kopyalarken, Elman ağında ilk gizli süreç ögelerinin faaliyeti kaynak ögelerine kopyalanır. Ayrıca girdiyi ve son gizli katmanı kaynak ögelerine besleyen ağlar da mevcuttur.



Şekil 5.14 Jordan ve Elman ağıının programdaki görüntüsü.

5.5 Principal Component Analysis (PCA) (Temel Bileşen Analizi)

Temel bileşen analizi ağları, denetlenmiş ve denetlenmemiş öğrenmeyi aynı topoloji içinde birleştirir. Temel bileşen analizi, girdiden karşılıklı ilişkisi olmayan nitelikler ve temel bileşenlerden oluşan bir dizi bulan, denetlenmemiş, lineer bir prosedürdür. Bir MLP bu bileşenlerden lineer olmayan sınıflandırma gerçekleştirmek için denetlenmiştir.




Şekil 5.15 PCA ağıının programdaki görüntüsü.

5.6 Rbf/Grnn/Pnn Network (Rbf) (Radyal Temelli Fonksiyon / Genelleştirilmiş Regresyon / Olasılıksal Ağlar)

Radyal temelli fonksiyon ağları, karakteristik olarak tek bir gizli katman süreç ögesi içeren, çizgisel olmayan melez ağlardır. Bu katman MLP tarafından görevlendirilmiş standart sigmoid fonksiyonlara tercihen Gaussian transfer fonksiyonlarını kullanır. Gaussianların merkezleri ve ağırlıkları denetlenmemiş eğitim kuralları tarafından belirlenmiştir ve çıktı katmanına denetlenmiş eğitim uygulanır. Bu ağlar MLP'lardan çok daha hızlı öğrenmeye eğilimlidir.

Bir genelleştirilmiş regresyon ağı (GRNN) ya da olasılıksal ağ (PNN) seçildiğinde ise ağıın tüm ağırlıkları analitik olarak hesaplanabilir. Bu durumda, küme merkezlerinin sayısı tanımda


örneklerin sayısına eşittir ve hepsi aynı varyansa ayarlanmıştır. Bu tip radyal temelli fonksiyonları sadece örneklerin sayısı çok küçükse (100'den küçük) ya da kümelemenin zar zor belirleneceği şekilde dağıtılmışlarsa kullanın.




Şekil 5.16 RBF ağının programdaki görüntüsü.

5.7 Self-Organizing Feature Map Network (Kendi Kendini Organize Eden Nitelik Haritası Ağları)

Kendi kendini organize eden nitelik haritası ağları (SOFM), isteğe bağlı boyut girdisini, topolojik (komşuluğu koruyan) sınırlamaya mecbur bir ya da iki boyutlu soyut bir haritaya dönüştürür. Nitelik haritaları, Kohonen denetlenmemiş eğitimi kullanılarak hesaplanır. SOFM'un çıktısı MLP'deki gibi, bir denetlenmiş sınıflandırma sinir ağına girdisi olarak kullanılabilir. Bu ağı temel avantajı, SOFM tarafından üretilmiş, kendini organize eden bir süreç kullanarak girdi alanını sembolik niteliklere düşürerek küçülten kümeleme özelliğidir. Bunun sonucu olarak girdi alanının boyutluluğu düşürülürken, alanın temelinde yatan yapı korunur. Kohonen özörgütlemeli haritasının yapısı Şekil 5.17'deki gibidir.




Şekil 5.17 Kohonen özörgütlemeli haritası.



Şekil 5.18 SOFM ağıının programdaki görüntüsü.

5.8 Time-Lag Recurrent Network (Gecikmeli Tekrarlanan Ağlar)


Gecikmeli tekrarlanan ağlar, kısa devreli hafıza yapıları ile genişletilmiş MLP'lardır. Çoğu gerçek dünya verisi, zaman yapısı içinde bilgi içerir, yani verinin zamana göre değişimi. Yine de çoğu sinir ağları katıksız statik sınıflandırıcılardır. TLRN'ler, lineer olmayan zaman serileri tahmininde, sistem tanımlanmasında ve geçici örnek sınıflandırılmasında ustadırlar.



Şekil 5.19 TLRN ağıının programdaki görüntüsü.

5.9 Recurrent Network (Yinelenen Ağlar)


Tam yinelenen ağlar, gizli katmanı kendisine geri beslerler. Kısmi yinelenen ağlar tam yinelenen bir ağ ile başlar ve yinelenen kısmı durum hafızası olarak etkin biçimde işleterek, tekrarlamayı bertaraf eden ileri beslemeli bir bağlantı eklerler. Bu yinelenen ağlar sonsuz bir hafıza derinliğine sahip olabilir ve böylece zaman sayesinde olduğu gibi ani girdi alanı sayesinde de bağlantılar bulurlar. Çoğu gerçek dünya verisi zaman yapısı içinde bilgi içerir. Yinelenen ağlar lineer olmayan zaman serileri tahmininde, sistem tanımlanmasında ve geçici örnek sınıflandırılmasında ustadırlar.



Şekil 5.20 Yinelenebilir ağırların programdaki görüntüsü.

5.10 Canfis Network (Fuzzy Logic) (Canfis Ağı - Bulanık Mantık)

CANFIS * (Birlikte etkin Sinirsel-Bulanık sonuç çıkarma sistemi) modeli, karmaşık fonksiyonları hızlı ve kesin bir şekilde yaklaştırmak için uyum sağlanabilir bulanık girdileri modüler sinir ağları ile entegre eder. Bulanık sonuç çıkarma sistemleri ayrıca kuralların açıklayıcı doğasını (üyelik fonksiyonları) "kara kutu" sinir ağlarının gücü ile birleştirmeleri yönünden de değerlidirler.




Şekil 5.21 Canfis ağının programdaki görüntüsü.

5.11 Support Vector Machine (Destek Vektör Makinesi)

Destek Vektör Makinesi (SVM), çekirdek Adatron algoritması kullanılarak uygulanır. Çekirdek Adatron girdileri yüksek boyutlu nitelik alanına haritalar ve sonra veri limitlerine

* Co-Active Neuro-Fuzzy Inference System

yakın düşen girdileri izole ederek veriyi optimal bir şekilde girdilerin tek tek sınıfları içine dağıtır. Bu nedenle çekirdek Adatron özellikle karmaşık limitleri paylaşan veri setlerini ayırmada etkilidir. SVM'ler sadece sınıflandırma için kullanılabilir, fonksiyon yaklaşması için kullanılamaz.



Şekil 5.22 SVM ağının programdaki görüntüsü.

Tüm bu modellerin özetini Çizelge 5.1’deki gibi yapmak mümkündür.

Çizelge 5.1 Yapay sinir ağları modelleri.

Model	Tanım	Avantajları ve Kullanımı
Multilayer Perceptron (MLP)	En çok kullanılan nöral ağ	Genel Sınıflandırma veya İlişki Yoklaması
Generalized Feedforward (GFF)	MLP artı ek katmandan katmana ileri bağlantılar	Standart MLP’nin üzerinde ek hesaplama gücü
Modular Feedforward	Çıktı’da birleşen birçok paralel MLPler.	Standart MLP’ye kıyasla katmanlar arası ağırlık sayısının azaltılması
Radial Basis Function (RBF)	Gaussian Axonların çizgisel birleşimi	Hızlı eğitim, Gaussian merkezlerinin ve genişliklerinin basit yorumlanması
Jordan and Elman	Uyumlu olmayan tekrarlayan geribildirimli MLP	MLP’ye sabit temporal bağımlılıkları olan basit temporal problemler için sabit hafıza ekler.
Principal Component Analysis (PCA) Hybrids	Girdide Denetlenmeyen PCA’i takip eden denetlenen MLP	Yüksek boyutlu gereksiz girdi verisini küçük boyuta yansıtır.Sonuç çıktıları ortogonaldır.
Self-Organizing Feature Map (SOFM) Hybrid	Girdide denetlenmeyen SOFM’i takip eden denetlenen MLP	Yüksek boyutlu veriyi komşuluk bölgesini koruyarak küçük boyuta yansıtır.
Time Lagged Recurrent	Yerel olarak	Kısa temporal bağımlılıkları


	tekrarlayan uyumlu katman(lar)	tek ağırlıklı olan temporal problemler için. Garantili istikrar. Verinin hafıza derinliği olarak, tekrarlayan ağırlığın basit yorumlaması.
General Recurrent	Tam veya kısmen tekrarlayan ağ	Daha zor temporal problemler, en güçlü nöral ağ, ve en zor eğitilen. Sıklıkla istikrarsızlaşır.
CANFIS	Girdide uyumlu havlı üyelik işlemi	Kötü tanımlanmış problemler. Havlı önişlem nöral ağın işini ayırıklaştırılması kolay olmayan girdileri nitelendirerek kolaylaştırır, sıklıkla genel olarak daha iyi bir modelle sonuçlanır.
Support Vector Machine	Kernal adatron algoritmasını kullanarak eğitilmiş.	Kesinlikle küçükten orta büyüklükte nitelendirilmiş problemler için kullanılır. SVM özellikle karmaşık sınırlar paylaşan bir takım veriyi ayırmada etkilidir.


İstenilen modelin seçilmesinin ardından topoloji paneli ile karşılaşılacaktır (Şekil 5.23).

Topoloji paneli ilk panelde seçilen nöral modele özeldir. Bu ekranda;

-Gizli katmanların sayısı


-İlk panelde seçilen mimariye özel parametreler (gizli katmanlar için, kaç gizli katman var ise, transfer fonksiyonu, öğrenme kuralı ve maksimum devir sayısı) değiştirilebilir.





Şekil 5.23 Topoloji ekranı.

Bir nöral ağı zor problemleri öğrenme sayısal yetisini veren gizli katmanın aksonlarının çizgisel olmayışıdır. NeuralBuilder tarafından önerilen sekiz akson bulunmaktadır (Şekil 5.23)



Şekil 5.24 İletim işlevi ve öğrenme kuralları

NeuralBuilder otomatik olarak NeuroSolutions'a girdi verilerini ilk gizli katmanın iletim işlevi aralığına uymasını için ölçeklendirmesi ve değiştirmesi talimatını verir. Örneğin, eğer ilk gizli katmanın aksonu bir TanhAxon ise, girdi verisi -1 ile 1 arasında olacak şekilde ölçeklendirilip değiştirilir. Bu önemli ön-işlem ayağına normalizasyon denir.

Değişim ölçüsü araması olarak da adlandırılan, Öğrenim Kuralları, ağırlık güncellemesini hesaplamakta kullanılır. NeuralBuilder beş öğrenim kuralı önerir (Şekil 5.24).


Tıpkı girdi verisi gibi, NeuralBuilder otomatik olarak istenilen yanıt verisini çıktı iletim işlevinin aralığına uymasını için normalize edecektir. Örneğin, Eğer çıktı katmanı bir TanhAxon ise, istenilen yanıt verisi -1 ve 1 aralığına gelecek şekilde normalize edilir.

Axon ailesinin iki işlevi vardır. Bileşenler tüm girdilerini toplar ve bu toplama bir işlev uygular. Axon ailesindeki farklı bileşenler, toplamalarına farklı işlevler uygularlar. Axon ailesi simgesindeki her bir farklı imge, uygulanan işlevi temsil eder. Çizgisel Axon (kısaca Axon olarak adlandırılır) girdilerinin toplamını direkt olarak çıktıya geçirir. Bias Axon

girdileri toplar ve bir uzantı ekler. Sigmoid Axon veriye eşiklenen işlevi uygular. Axon ailesinin tek bir bileşeni bir çok PE'leri temsil edebilir.


Synapse ailesi Axonları birbirine bağlamak için kullanılır. Genel olarak, bir Synapse'daki her bir bağlantıya içinden geçen veriyi ölçeklendiren bir ağırlık verilir. Bu ağırlıkları ayarlayarak bir nöral ağ veya uyumlu sistem istenilen görevi yapması için eğitilir. Synapse ailesinin en çok kullanılan üyesi FullSynapse'dır ve bir Axon bileşenindeki tüm PE'leri diğer bir Axondaki bileşenlere bağlar. Böylece, eğer PE'lerde n girdisi ve m çıktı PE'leri varsa, FullSynapse bileşeni nm bağlantılarını (ve ağırlıklarını) içerir.

Ağ modelinin seçilmesinin ardından ağın eğitilme süreci başlatılır (Şekil 5.25).




Şekil 5.25 Ağın eğitiminin başlatılması.

Parametreler arasında sembol bulunuyorsa ekrana Şekil 5.26'daki uyarı çıkmaktadır. Bu işlem kabul edildiğinde sembolik tüm parametreler sayısal değerlere çevrilmektedir. ayrıntılı veri Ek 2'de yer almaktadır.




Şekil 5.26 Sembolik değerlerin sayısal değerlere çevrilmesi.

Öğrenmenin gerçekleşmesi için devir sayısının belirlenmesi gerekmektedir (Şekil 5.27).



Şekil 5.27 Öğrenme için devir sayısının belirlenmesi.

Eğitim sürecinin başlamasının ardından program, eğitimin ne kadar süreceğini öngörmektedir (Şekil 5.28). Bu ağın yapısına, verinin büyüklüğüne, belirlenen devir sayısına, eğitimin kaç kez tekrarlanacağına, gizli katman sayısına, öğrenme algoritmalarına bağlı olarak farklılık göstermektedir. Yapılan eğitimlerde 13 saat ile 2 dakikalık eğitim süreleriyle karşılaşılmış ve eğitimler bu öngörülen sürelerde tamamlanmıştır. Bu süre bilgisayar işlemcisinin hızı ve CPU kullanımıyla da doğrudan alakalıdır.



Şekil 5.28 Öngörülen eğitim süresi.

5.12 Uygulama Sonuçları

Yapılan eğitimler kullanılan YSA modeli, gizli katman sayısı, kullanılan akson çeşidi ve algoritması, eğitim sayısı, maksimum devir sayısı ve eğitimler sonrasında elde edilen minimum hatalar Çizelge 6.1’de listelenmiştir. Eğitimlere ait son hatalar ve minimum hatalar ayrıca Çizelge 6.2’de sıralanmıştır. Burada daha önce de belirtildiği gibi eğitimin sonucunda minimum hatayı elde edebiliyor olmak ve minimum hatayı veren sonuçlar için gerçekten tutarlı tahminleri tespit etmek önem taşımaktadır.

Çizelge 6.1 Eğitimler

DENEMELER	KULLANILAN YSA MODELİ	GİZLİ KATMAN SAYISI	AXON	ÖĞRENME ALGORİTMASI	EĞİTİM SAYISI	MAXIMUM DEVİR SAYISI	MİNİMUM HATA
1	Genelleştirilmiş İleri Besleme	1	TahnAxon	Momentum	1	10000	0,001779616
2	Modüler Sinir Ağları	1	TahnAxon	Momentum	2	10000	0,001841032
3	Jordan Ve Elman Ağı	1	TahnAxon	Momentum	1	10000	0,003190698
4	Temel Bileşen Analizi	1	TahnAxon	Momentum	2	10000	0,003530069
5	Radyal Temelli Fonksiyon / Genelleştirilmiş Regresyon / Olasılıksal Ağlar	1	TahnAxon	Momentum	1	10000	0,005099326
6	Kendi Kendini Organize Eden Nitelik Haritası Ağları	1	TahnAxon	Momentum	1	10000	0,005163438
7	Gecikmeli Tekrarlanan Ağlar	1	TahnAxon	Momentum	1	10000	0,004528245
8	Yinelenen Ağlar	1	TahnAxon	Momentum	1	11000	0,003091752
9	Canfis Ağı - Bulanık Mantık	1	TahnAxon	Momentum	3	10000	0,005318355
10	Canfis Ağı - Bulanık Mantık	1	TahnAxon	Momentum	1	10000	0,011151695
11	Çok Katmanlı Algılayıcı	2	TahnAxon	Momentum, LevenbergMaquart	2	1000	6,91314E-05
12	Genelleştirilmiş İleri Besleme	2	TahnAxon	Momentum, LevenbergMaquart	1	1000	0,00010057
13	Modüler Sinir Ağları	2	TahnAxon	Momentum, LevenbergMaquart	1	1000	1,11838E-05
14	Jordan Ve Elman Ağı	2	TahnAxon	Momentum, LevenbergMaquart	1	1000	0,000106037
15	Temel Bileşen Analizi	2	TahnAxon	Momentum, LevenbergMaquart	1	1000	0,000174269
16	Temel Bileşen Analizi	3	TahnAxon	Momentum, LevenbergMaquart	1	1000	0,001605798
17	Kendi Kendini Organize Eden Nitelik Haritası Ağları	2	TahnAxon	Momentum, LevenbergMaquart	1	1000	0,005163433
18	Gecikmeli Tekrarlanan Ağlar	2	TahnAxon	Momentum, LevenbergMaquart	1	1000	4,87204E-05
19	Yinelenen Ağlar	2	TahnAxon	Momentum, LevenbergMaquart	1	1000	0,005102957
20	Çok Katmanlı Algılayıcı	3	TahnAxon	Momentum, LevenbergMaquart	1	1000	7,09719E-05
21	Genelleştirilmiş İleri Besleme	3	TahnAxon	Momentum, LevenbergMaquart	1	1000	0,006785953
22	Modüler Sinir Ağları	6	TahnAxon	Momentum, LevenbergMaquart	1	1000	0,453335045
23	Çok Katmanlı Algılayıcı (Promosyon Etkisi Yok)	2	TahnAxon	Momentum, LevenbergMaquart	1	1000	0,006032977

Çizelge 6.2 Son ve minimum hatalar

EĞİTİMLER	HATALAR	SONUÇLAR
DENEME 1	Minimum MSEs	0,001779616
DENEME 1	Final MSEs	0,001779616
DENEME 2	Minimum MSEs	0,001841032
DENEME 2	Final MSEs	0,001841032
DENEME 3	Minimum MSEs	0,003190698
DENEME 3	Final MSEs	0,003190698
DENEME 4	Minimum MSEs	0,003530069
DENEME 4	Final MSEs	0,003530069
DENEME 5	Minimum MSEs	0,005099326

EĞİTİMLER	HATALAR	SONUÇLAR
DENEME 5	Final MSEs	0,005099326
DENEME 6	Minimum MSEs	0,005163438
DENEME 6	Final MSEs	0,005163438
DENEME 7	Minimum MSEs	0,004528245
DENEME 7	Final MSEs	0,004528245
DENEME 8	Minimum MSEs	0,003091752
DENEME 8	Final MSEs	0,003091752
DENEME 9	Minimum MSEs	0,005318355
DENEME 9	Final MSEs	0,005318355
DENEME 10	Minimum MSEs	0,011151695
DENEME 10	Final MSEs	0,011151695
DENEME 11	Minimum MSEs	6,91314E-05
DENEME 11	Final MSEs	6,91332E-05
DENEME 12	Minimum MSEs	0,00010057
DENEME 12	Final MSEs	0,000102148
DENEME 13	Minimum MSEs	1,11838E-05
DENEME 13	Final MSEs	1,11838E-05
DENEME 14	Minimum MSEs	0,000106037
DENEME 14	Final MSEs	0,000108096
DENEME 15	Minimum MSEs	0,000174269
DENEME 15	Final MSEs	0,000174269
DENEME 16	Minimum MSEs	0,001605798
DENEME 16	Final MSEs	0,002415454
DENEME 17	Minimum MSEs	0,005163433
DENEME 17	Final MSEs	0,005163433
DENEME 18	Minimum MSEs	4,87204E-05
DENEME 18	Final MSEs	4,87204E-05
DENEME 19	Minimum MSE	0,005102957
DENEME 19	Final MSE	0,005102958
DENEME 20	Minimum MSEs	7,09719E-05
DENEME 20	Final MSEs	7,12451E-05
DENEME 21	Minimum MSEs	0,006785953
DENEME 21	Final MSEs	0,006785953
DENEME 22	Minimum MSE	0,453335045
DENEME 22	Final MSE	0,453335045
DENEME 23	Minimum MSEs	0,006032977
DENEME 23	Final MSEs	0,006032977

Çizelge 6.3'te eğitimler sonucunda geçmiş verilere istinaden sistemin farklı öğrenme algoritmalarına sahip farklı denemeler sonucunda elde edilen tahminler yer almaktadır. “X” ile işaretli alanlar ilgili ürüne ait promosyonun olduğunu belirtmektedir. Tahmini yapılacak tarihin hangi özel gün, haftanın hangi günü, yılın hangi mevsimi ve promosyon bilgileri bilinmektedir. Sonuçlar incelendiğinde, denemeler arasında birbirine yakın minimum hata veren 4 deneme dikkat çekmektedir (Çizelge 6.2). Bu dört denemeden (Deneme 11, 13, 18, 20) elde edilen tahminler incelendiğinde (Çizelge 6.3), gerçek verilere en yakın sonuçlar

veren Deneme 11'dir. Çünkü ani ve yüksek satış beklentilerinin bulunduğu şartlarda en yüksek değerleri veren, normal satışlara nazaran daha çok satış yapılması planlanan zamanlarda (promosyon zamanları gibi) daha yüksek sonuçlar veren örnek Deneme 11 olmaktadır.. Deneme 11'de Çizelge 6.1'de görüldüğü gibi iki gizli katman, Momentum ve Levenberg Maquart öğrenme algoritmaları kullanılmıştır ve maksimum devir sayısı 1000'dir.

Çizelge 6.3 Sistemden elde edilen tahminler

YIL	2011	2010	2010	2010	2010	2010	2010	2010	2010	2010
AY	12	5	5	31	15	16	17	20	18	11
GÜN	31	15	16	12	5	5	7	7	8	8
GÜN ADI	CTS	PZR	PTS	CTS	PZR	PTS	CTS	PZR	PZR	CARS
MEVSİM	KIS	ILKBAHAR	ILKBAHAR	KIS	ILKBAHAR	ILKBAHAR	YAZ	YAZ	YAZ	YAZ
ÖZEL GÜNLER	YILBASI			YILBASI						
COCA 1 LT										
PEPS 2.5 LT										X
COCA 2.5 LT			X			X	X	X	X	
COCA 1 LT Satış miktarı	25	25	20	25	25	20	25	25	25	30
PEPS 2.5 LT Satış miktarı	25	25	20	25	25	20	25	25	25	20
DENEME 1	2.509	107	376	273	441	949	1.202	103	511	-83
DENEME 2	718	114	110	447	98	103	265	148	110	78
DENEME 3	146	139	139	151	139	139	143	144	147	139
DENEME 4	121	109	110	119	109	111	164	135	149	108
DENEME 5	151	142	140	145	150	148	154	160	155	130
DENEME 6	151	151	151	151	151	151	151	151	151	151
DENEME 7	130	130	130	130	130	130	130	130	130	130
DENEME 8	443	1.279	20	-145	-186	987	2.101	-9	440	-187
DENEME 9	113	113	244	113	113	244	255	255	255	74
DENEME 10	1.200	329	1.481	1.960	-2.796	-1.302	-1.107	-1.682	-1.133	3.481
DENEME 11	5.478	115	498	221	945	757	380	375	4.492	178
DENEME 12	5.840	151	26	-277	-44	1.258	5.763	-277	184	96
DENEME 13	5.849	188	76	31	96	75	421	128	196	113
DENEME 14	5.799	213	103	5.284	104	50	194	118	1.986	113
DENEME 15	149	118	105	154	126	103	178	200	188	89
DENEME 16	148	148	148	148	148	148	251	251	251	110
DENEME 17	151	151	151	151	151	151	151	151	151	151
DENEME 18	511	105	139	5.804	102	121	2.435	3.994	4.376	76
DENEME 19	228	110	144	-166	117	192	110	-149	120	110
DENEME 20	2.835	431	107	3.792	131	119	97	88	84	107
DENEME 21	133	93	-200	102	63	-95	-249	-253	-255	-205
DENEME 22	3.047	3.045	3.052	3.050	3.048	3.045	3.070	3.051	3.046	3.046

Denemeler arasında en iyi sonucu Deneme 11 vermesi sebebiyle bu denemenin şartlarının aynen yerine getirildiği fakat girdi olarak sadece geçmiş satışların yer aldığı Deneme 23'ün minimum hatası ölçülmüştür. Burada talebi etkilediği iddia edilen parametrelerin gerçekten etkili olup olmadığı kanıtlanmak istenmiştir. Sistem geçmiş satış verileriyle eğitilmiş ve minimum hatası ölçülmüştür (Deneme 23/Çizelge 6.1-Çizelge 6.2). Fakat bu denemeler sonucunda görülmüştür ki her iki deneme için minimum hata arasında oldukça büyük farklar bulunmaktadır (Deneme 11, Deneme 23/Çizelge 6.1, Çizelge 6.2). Bu da promosyon ve özel günlerin etkisinin satışlar üzerinden önemli bir etkisi olduğunu göstermektedir.

6. SONUÇLAR

Her geçen gün değişen ve gelişen dünyada insanların hedefleri, istekleri, ihtiyaçları da bu değişime ayak uydurmakta ve değişmektedir.

Dün,

- Ürüne ve hizmete aç
- Fazla beklentisi olmayan
- Bulduğu mala ve hizmetle yetinen
- Fazla seçme ve karşılaştırma şansı olmadığı için eleştirmeyen (kabalıcı)

Bugün,

- Beğeni ve tercihleri hızla değişen
- Hep daha fazlasını isteyen
- Daha fazla karşılaştıran ve eleştiren
- Her geçen gün daha çok bilinçlenen bir müşteri profiliyle karşı karşıya kalınmıştır.

Bu durum ise müşterinin sizin ürününüzü seçip seçmeyeceği, gramaj, renk, boy gibi fiziksel özelliklerinden ötürü kendi ürününüzün farklı gramaj, renk veya boyunu tercih etmeyeceği, başka bir ürünü deneme isteği duymayacağı, denediği takdirde diğer ürünü tercih etmeyeceği anlamına gelmemektedir. Bu da ürün için satış tahminlerini alt üst edecektir. Fakat burada size rehberlik edecek olan, ürününüzü ön plana çıkaracak hangi uygulamayı yaptığınız (indirim, promosyon, çapraz promosyon vb.), ürününüzün kalitesi, fiyatı, özel günlere verdiği reaksiyon ve geçmişte benzer şartlarda nasıl bir satış davranışı sergilediğidir.

Daha önce de belirtildiği gibi müşterilerin ihtiyaçları, coğrafik, demografik, psikolojik, sosyokültürel ve kullanıcıya sağladığı faydaya göre farklılık göstermektedir ve günün şartlarında insan ihtiyaçlarını karşılayacak ve bir o kadar ürünün alımı cazip hale getirilen, farkında olmadan özel zamanlarda bir gereklilikmiş gibi yansıtılarak satılan tüm hızlı tüketim mallarında “lüks”ün aslında bir ihtiyaç olduğu algısı farkında olmadan yaratılmıştır. Bu sebeple perakende sektöründe ürünün müşteri için gerekli kılındığı önemli günler, mevsim ve zamanlar iyi değerlendirilmektedir. Buna bahar aylarında temizlik ve temizlik yan ürünlerinin ön plana çıkarılması, yılbaşı arifesinde içkiler, çerez ve cipslerin ön plana çıkarılması, ramazan ayında bakliyat ürünlerinin ön plana çıkarılması örneği verilebilir. Bu zamanlarda bu ürünlerin ön plana çıkarılması ürünlerin bu dönemde müşterinin ihtiyacı olduğu algısını yaratmaktadır. Bu zamanlarda yapılan indirimler, promosyonlar, teşhirler, yazılı ve görsel basınla yapılan duyurular müşterilerin alışveriş listelerini değiştirmekte, dolayısıyla da talep

tahmini esnasında tüm bunları göz önünde bulunduracak modellerin seçilmesi gerekliliği doğurmaktadır.

Aslında talep tahmininde anlatılan psikolojik, demografik, sosyal etmenler satışların kaderini belirlemekte bu sebeple de talebi tahmin eden mekanizmalarında bu konulara dikkat çekmesi gerektiğini işaret etmektedir.

Çalışmada aynı öğrenme algoritmasının kullanılmış olmasına rağmen farklı çıkan bu sonuçlar göstermektedir ki özel günler, mevsim ve promosyon bilgileri talebin tahmininde en etkili kriterlerdir.

Türkiye'deki perakendecilik sektörü de ekonomik yaşamdan çok toplumdaki psikolojik hareketlilikten etkileniyor denebilmektedir. Çünkü bir ürünü satışını bir özel gün sebebiyle kat kat fazla arttığı görülüyorsa bu sonuca varmak çok da zor olmaz.

Müşteri ihtiyaç ve alışveriş davranışlarının birçoğu hesaplanabilir değişkenler içermediği halde kullanılan yöntemle talep tahminin kilit noktası olan bu değişkenler hesaplanabilir ve tahminlemeye dahil hale getirmek mümkün olmuştur. Çalışmadan çıkan sonuçlar gerçek satışlarla kıyaslandığında tatmin edici sonuçlar vermiştir. Türkiye'de perakende sektöründe talep tahmini için anahtar nokta promosyonların etkisi ve ürünü gerekli kılan önemli günler ve dönemlerdir .

Bu çerçevede talebi tahmin edilmek istenen bir ürün için doğru model kurulduğunda istenilen parametre değiştirilerek yeni sonuçlar elde edilebilmektedir.

KAYNAKLAR

- Armstrong, J. S., (1988), "Research needs in forecasting", *International Journal of Forecasting*, 4(3): 449–465.
- Armstrong, J.S., Morwitz, V.G. ve Kumar, V., (2000), "Sales forecasts for existing consumer products and services: Do purchase intentions contribute to accuracy?", *International Journal of Forecasting*, 16 (2000):383–397.
- Bayraktaroğlu, İ., (1996), "Circuit level simulation based training algorithms for analog neural Networks", *Yüksek Lisans Tezi, Boğaziçi Üniversitesi Fen Bilimleri Enstitüsü*.
- Broomhead, D. S. ve Lowe, D., (1988), "Multi-variable functional interpolation and adaptive networks", *Complex Systems*, 2:321-355.
- Davis, D. ve Mentzer, J.T., (2007), "Organizational factors in sales forecasting management", *International Journal of Forecasting*, 23(3):475–495.
- Deitel, H.M., (2002), *C# : How To Program*, Prentice Hall, New Jersey.
- Demir, H. ve Gümüşoğlu, Ş., (2003), *497/Üretim Yönetimi-İşlemler Yönetimi (6. Baskı)*, Beta Basım Yayım, İstanbul.
- Efe, Ö. ve Kaynak, O., (2000), *Yapay Sinir Ağları ve Uygulamaları*, Boğaziçi Üniversitesi Yayınevi, İstanbul.
- Elmas Ç., (2003), *Yapay Sinir Ağları: Kuram, Mimari, Eğitim, Uygulama*, Seçkin Yayıncılık, Ankara.
- Fildes, R. ve Beard, C., (1992), "Forecasting systems for production and inventory control", *International Journal of Operations and Production Management*, 12(5): 4–27.
- Fildes, R. ve Hastings, R., (1994), "The organization and improvement of market forecasting", *Journal of the Operations Research Society*, 45(1):1–16.
- Fildes, R., (2006), "The forecasting journals and their contribution to forecasting research: Citation analysis and expert opinion", *International Journal of Forecasting*, 22(3):415–432.
- Fildes, R., Goodwin, P. ve Lawrence, M., (2006), "The design features of forecasting support systems and their effectiveness", *Decision Support Systems*, 42(1): 351–361.
- Fildes, R., Goodwin, P., Lawrence, M. ve Nikolopoulos, K., (2008), "Effective forecasting and judgmental adjustments: an empirical evaluation and strategies for improvement in supply-chain planning", *International Journal of Forecasting*, 25(2009):3–23.
- Frank, C., Garg, A., Raheja, A. ve Sztandera, L., (2002), "Forecasting women's apparel sales using mathematical modeling", *International Journal of Clothing Science and Technology*, 15(2):107–125.
- Galbraith, C. S. ve Merrill, G. B., (1996), "The politics of forecasting managing the truth", *California Management Review*, 38(2):29–43.

- Galbraith, C.S. ve Merrill, G.B., (1996), "The politics of forecasting: Managing the truth", *California Management Review*, **38**(2):29–43.
- Gardner, E. S. Jr., (1990), "Evaluating forecasting performance in an inventory control system", *Management Science*, **36**(4):490–499.
- Gardner, H., (1983), *Frames of mind: The theory of multiple intelligences*, Basic Books, New York.
- Gullien, G., Mele, F.D., Bagajewicz, M.J., Espuna, A. ve Puigjaner, L., (2005), "Multiobjective supply chain design under uncertainty", *Chemical Engineering Science*, **60**:1535-1553.
- Gupta, A. ve Maranas, C.D., (2003), "Managing demand uncertainty in supply chain planning", *Computer and Chemical Engineering*, **27**:1219–1227.
- Gupta, A. ve Maranas, C.D., (2003), "Managing demand uncertainty in supply chain planning", *Computer and Chemical Engineering*, **27**:1219-1227.
- Gutierrez, R.S., Solis, A.O. ve Mukhopadhyay, S., (2008), "Lumpy demand forecasting using neural networks", *International Journal of Production Economics* **111**(2):409–420.
- Hill, T., O'Connor, M. ve Remus, W., (1996), "Neural network models for time series forecasts", *Management Science*, **42**:1082–1092.
- Iman, R. ve Conovar, W.J., (1983), *Modern Business Statistics*, Wiley Press, New York.
- Karabuk, S. ve Wu, S. D., (2003), "Coordinating strategic capacity planning in the semiconductor industry", *Operations Research*, **51**(6):839-849.
- Karabuk, S. ve Wu, S.D., (2003). Coordinating strategic capacity planning in the semiconductor industry, *Operations Research*, **51**(6):839-849.
- Kayhan Tarhan, M., (2003), "An Axiomatic Design Approach to Demand Forecasting Applications in Retailing", *Doktora Tezi*, Marmara Üniversitesi Fen Bilimleri Enstitüsü.
- Kerkkanen, A., Korpela, J. ve Huiskonen, J., (2009), "Demand forecasting errors in industrial context: Measurement and impacts", *International Journal of Production Economics*, **118**(1):43-48.
- Klassen, R.D. ve Flores, B.E., (2001), "Forecasting Practices of Canadian Firms: Survey Results and Comparisons", *International Journal of Production Economics*, **70**(2): 163-174.
- Ko, M., Tiwari, A. ve Mehnen, J., (2010), "A review of soft computing applications in supply chain management", *Applied Soft Computing*, **10**(3):661-674.
- Kress, G.J. ve Snyder, J., (1994), *Forecasting and Market Analysis Techniques: A Practical Approach*, Quorum Books, USA.

Kusters, U., McCullough, B. D. ve Bell, M., (2006), "Forecasting software: Past, present and future", *International Journal of Forecasting*, 22(3):599–615.

Luxhoj, J.T., Riis, J.O. ve Stensballe, B., (1996), "A hybrid econometric–neural network modeling approach for sales forecasting", *International Journal of Production Economics*, 43(2–3):175–192.

Makridakis, S.G., (1990), *Forecasting, Planning, and Strategy for the 21st Century*, The Free Press, New York.

Maltz E. ve Srivastava, R.K., (1998), "Managing Retailer-Supplier Partnerships with EDI: Evaluation and Implementation", *Long Range Planning*, 30-6 (1997): 862-876.

Mason-Jones, R., Naylor, B. ve Towill, D.R., (2000), "Lean, agile or leagile? Matching your supply chain to the marketplace", *International Journal of Production Research*, 38(17):4061— 4070.

Matuyama, K., Sumita, T. ve Wakayama, D., (2009), "Periodic forecast and feedback to maintain target inventory level", *International Journal of Production Economics*, 118(1):298-304.

McLaughlin, R. L., (1979), *Organisational forecasting: its achievements and limitations*, In: S. Makridakis, & S. C. Wheelwright Editors, *TIMS studies in the management science*, 12:17–30.

Memmedov, M. ve Eryılmaz, H., (2003), "Yapay Sinir Ağları ile Bazı İstatiksel Modeller Arasındaki İlişki", *Uluslararası XII Türkiye Yapay Zeka ve Sinir Ağları Sempozyumu*, TAIN-03, 02-04 Temmuz 2003, Çanakkale.

Mentzer, J. T. ve Cox, Jr. J. E., (1984), "Familiarity, application and performance of sales forecasting techniques", *Journal of Forecasting*, 3:27–36.

Mentzer, J. T., Bienstock, C. C. ve Kahn, K. B., (1999), "Benchmarking sales forecasting management", *Business Horizons*, 42(3):48–56.

Mentzer, J.T. ve Moon, M.A., (2005), *Sales Forecasting Management: A Demand Management Approach*, Sage Publications, California.

Monks, J.G., (1987), *Operations Management (3rd Edition)*, McGraw-Hill International Editions, Singapore.

Öztemel E., (2003), *Yapay Sinir Ağları*, Papatya Yayıncılık, İstanbul.

Peterson, R. T., (1993), "Forecasting practices in retail industry", *Journal of Business Forecasting*, 2(1), 11–14.

Remus, W. ve Simkin, M. G., (1987), "Integrating forecasting and decision making, In: S.

Makridakis, & S. C. Wheelwright Editors, *The handbook of forecasting: a manager' s guide (2nd ed.)*, Wiley, New York.

Render, B. ve Stair, R.M., (2000), *Quantitative Analysis for Management* (7th Edition), Prentice- Hall Inc., USA.

Sanders, N. R. ve Ritzman, L. P., (1992), "The need for contextual and technical knowledge in judgmental forecasting", *Journal of Behavioral Decision Making*, 5:39–52.

Sanders, N. R. ve Manrodt, K.B., (2003), "The Efficacy of Using Judgmental versus Quantitative Forecasting Methods in Practice", *International Journal of Management Science*, 31(6):511-522.

Schroeder, R.G., (1989), *Operations Management: Decision Making in the Operations Function* (3rd Edition), McGraw-Hill Book Co., Singapore.

Smith, C.D. ve Mentzer, J.T., (2009), "Forecasting task-technology fit: The influence of individuals, systems and procedures on forecast performance", *International Journal of Forecasting*, 26 (2010): 144–161.

Song, H. ve Li, G., (2008), "Tourism demand modelling and forecasting—A review of recent research", *Tourism Management*, 29 (2008):203–220.

Stevenson, W. J., (1989), *Introduction to Management Science*, Irwin Inc, USA.

Sun, Z.L., Au, K.F. ve Choi, T.M., (2007), "A neuro-fuzzy inference system through integration of fuzzy logic and extreme learning machines", *IEEE Transactions on Systems, Man, and Cybernetics: Part B*, 37 (2007):1321–1331.

Sztandera, L.M., Frank, C. ve Vemulapali, B., (2004), "Prediction of women's apparel sales using soft computing methods", *Lecture Notes in Computer Science*, 3215(2004):506–512.

Thomassey, S., Happiette, M. ve Castelain, J.M., (2005), "A global forecasting support system adapted to textile distribution", *International Journal of Production Economics*, 96(1):81–95.

Wacker, J.G. ve Lummus, R.R., (2002), "Sales forecasting for strategic resource planning", *International Journal of Operations and Production Management*, 22(9):1014–1031.

Weiland, A. ve Leighton, R., (1988), *Geometric analysis of neural network capabilities*. Technical Report, Arpanet III, pp. 385–392.

West, D. C., (1994), "Number of sales forecast methods and marketing management", *Journal of Forecasting*, 13(4):395–407.

Winklhofer, H., Diamantopoulos, A. ve Witt, S. F., (1996), "Forecasting practice: A review of the empirical literature and an agenda for future research", *International Journal of Forecasting*, 12:193–221.

Winklhofer, H. ve Diamantopoulos, A., (2003), "A model of export sales forecasting behavior and performance development and testing", *International Journal of Forecasting*, 19(2):271-285.

Wu, P., Fang, S., King, R.E. ve Nuttle, H.L.W., (1994), "Decision surface modelling of apparel retail operations using neural network technology". In: *Proceedings of IEEE 1994*

Textile, Fiber and Film Industrial Conference, 4-5 May 1994, Greenville, South Carolina, USA.

Wu, P., Yang, W. ve Wei, N., “An electromagnetism algorithm of neural network analysis—An application to textile retail operation”, *Journal of Chinese Institute of Industrial Engineers*, 21(1):59–67.

Yelland, P. M., (2006), “Stable seasonal pattern models for forecast revision: A comparative study”, *International Journal of Forecasting*, 22:799–818.

EK 1

Y	M	D	GÜN	MEVSİM	ÖZEL GÜNLER	COCA-COLA 1 LİTRE PROMOSYON	PEPSİ COLA 2.5 LT PROMOSYON	COCA-COLA 2.5 L PROMOSYON	COCA-COLA 1 LİTRE Satış miktarı	PEPSİ COLA 2.5 LT Satış miktarı	COCA-COLA 2.5 L Satış miktarı
2008	1	1	Salı	KIS			PEPSİ PROMOSYON		23	15	82
2008	1	2	Çrş	KIS			PEPSİ PROMOSYON		31	4	104
2008	1	3	Perş	KIS					21	10	67
2008	1	4	Cuma	KIS					31	16	117
2008	1	5	Cts	KIS					44	17	259
2008	1	6	Pzr	KIS					37	29	250
2008	1	7	Pts	KIS					22	12	155
2008	1	8	Salı	KIS					25	12	148
2008	1	9	Çrş	KIS					21	29	67
2008	1	10	Perş	KIS					21	13	90
2008	1	11	Cuma	KIS				COCA COLA 2.5 PROMOSYON	28	16	103
2008	1	12	Cts	KIS				COCA COLA 2.5 PROMOSYON	34	21	151
2008	1	13	Pzr	KIS				COCA COLA 2.5 PROMOSYON	34	37	141
2008	1	14	Pts	KIS				COCA COLA 2.5 PROMOSYON	37	14	94
2008	1	15	Salı	KIS					23	6	96
2008	1	16	Çrş	KIS					18	8	65
2008	1	17	Perş	KIS					45	15	89
2008	1	18	Cuma	KIS			PEPSİ PROMOSYON	COCA COLA 2.5 PROMOSYON	32	29	97
2008	1	19	Cts	KIS			PEPSİ PROMOSYON	COCA COLA 2.5 PROMOSYON	42	56	186
2008	1	20	Pzr	KIS			PEPSİ PROMOSYON	COCA COLA 2.5 PROMOSYON	24	43	148
2008	1	21	Pts	KIS			PEPSİ PROMOSYON	COCA COLA 2.5 PROMOSYON	47	17	84
2008	1	22	Salı	KIS			PEPSİ PROMOSYON		39	19	74
2008	1	23	Çrş	KIS			PEPSİ PROMOSYON		24	12	103
2008	1	24	Perş	KIS			PEPSİ PROMOSYON		36	20	106
2008	1	25	Cuma	KIS			PEPSİ PROMOSYON	COCA COLA 2.5 PROMOSYON	23	23	127
2008	1	26	Cts	KIS			PEPSİ PROMOSYON	COCA COLA 2.5 PROMOSYON	64	54	208
2008	1	27	Pzr	KIS			PEPSİ PROMOSYON	COCA COLA 2.5 PROMOSYON	48	52	210
2008	1	28	Pts	KIS			PEPSİ PROMOSYON	COCA COLA 2.5 PROMOSYON	51	33	80
2008	1	29	Salı	KIS			PEPSİ PROMOSYON		38	30	48
2008	1	30	Çrş	KIS			PEPSİ PROMOSYON		41	10	94
2008	1	31	Perş	KIS					55	2	111
2008	2	1	Cuma	KIS				COCA COLA 2.5 PROMOSYON	59	20	116
2008	2	2	Cts	KIS				COCA COLA 2.5 PROMOSYON	63	20	255
2008	2	3	Pzr	KIS				COCA COLA 2.5 PROMOSYON	94	13	203
2008	2	4	Pts	KIS				COCA COLA 2.5 PROMOSYON	41	5	139
2008	2	5	Salı	KIS					46	29	110
2008	2	6	Çrş	KIS					46	56	119
2008	2	7	Perş	KIS					60	40	95
:											
:											
2009	11	23	Pts	SONBAHAR		COCA COLA 1 PROMOSYON	1		194	43	82
2009	11	24	Salı	SONBAHAR		COCA COLA 1 PROMOSYON	1		136	35	128
2009	11	25	Çrş	SONBAHAR		COCA COLA 1 PROMOSYON	1		196	64	180
2009	11	26	Perş	SONBAHAR	ARIFE	COCA COLA 1 PROMOSYON	1		205	181	469
2009	11	27	Cuma	SONBAHAR	DİNİ BAYRAM	COCA COLA 1 PROMOSYON	1		82	63	96

Y	M	D	GÜN	MEVSİM	ÖZEL GÜNLER	COCA-COLA 1 LİTRE PROMOSYON	PEPSİ COLA 2.5 LT PROMOSYON	COCA-COLA 2.5 L PROMOSYON	COCA-COLA 1 LİTRE Satış miktarı	PEPSİ COLA 2.5 LT Satış miktarı	COCA-COLA 2.5 L Satış miktarı
2009	11	28	Cts	SONBAHAR	DİNİ BAYRAM	COCA COLA 1			149	28	159
2009	11	29	Pzr	SONBAHAR	DİNİ BAYRAM	COCA COLA 1			135	53	136
2009	11	30	Pts	SONBAHAR	DİNİ BAYRAM	COCA COLA 1			279	33	95
2009	12	1	Salı	KIS		COCA COLA 1			139	14	75
2009	12	2	Çrş	KIS		COCA COLA 1			461	17	61
2009	12	3	Perş	KIS		COCA COLA 1		COCA COLA 2.5	30	12	48
2009	12	4	Cuma	KIS		COCA COLA 1		COCA COLA 2.5	32	12	88
2009	12	5	Cts	KIS		COCA COLA 1		COCA COLA 2.5	50	39	197
2009	12	6	Pzr	KIS		COCA COLA 1		COCA COLA 2.5	45	16	176
2009	12	7	Pts	KIS		COCA COLA 1		COCA COLA 2.5	25	13	81
2009	12	8	Salı	KIS		COCA COLA 1		COCA COLA 2.5	27	12	86
2009	12	9	Çrş	KIS		COCA COLA 1		COCA COLA 2.5	37	13	103
2009	12	10	Perş	KIS		COCA COLA 1		COCA COLA 2.5	27	7	125
2009	12	11	Cuma	KIS		COCA COLA 1		COCA COLA 2.5	35	13	120
2009	12	12	Cts	KIS		COCA COLA 1		COCA COLA 2.5	56	32	472
2009	12	13	Pzr	KIS		COCA COLA 1		COCA COLA 2.5	49	39	496
2009	12	14	Pts	KIS		COCA COLA 1		COCA COLA 2.5	31	13	175
2009	12	15	Salı	KIS		COCA COLA 1		COCA COLA 2.5	26	27	93
2009	12	16	Çrş	KIS		COCA COLA 1		COCA COLA 2.5	41	20	90
2009	12	17	Perş	KIS		COCA COLA 1		COCA COLA 2.5	45	38	92
2009	12	18	Cuma	KIS		COCA COLA 1		COCA COLA 2.5	32	47	78
2009	12	19	Cts	KIS		COCA COLA 1		COCA COLA 2.5	63	96	731
2009	12	20	Pzr	KIS		COCA COLA 1		COCA COLA 2.5	53	77	638
2009	12	21	Pts	KIS		COCA COLA 1		COCA COLA 2.5	33	58	377
2009	12	22	Salı	KIS		COCA COLA 1		COCA COLA 2.5	20	66	76
2009	12	23	Çrş	KIS		COCA COLA 1		COCA COLA 2.5	40	69	118
2009	12	24	Perş	KIS					41	32	130
2009	12	25	Cuma	KIS					49	39	125
2009	12	26	Cts	KIS					70	94	233
2009	12	27	Pzr	KIS	SUKRAN GÜNÜ				42	86	201
2009	12	28	Pts	KIS					30	34	78
2009	12	29	Salı	KIS					26	26	113
2009	12	30	Çrş	KIS					64	78	813
2009	12	31	Perş	KIS	YILBASI				113	107	1605
2010	1	1	Cuma	KIS		COCA COLA 1	PEPSİ PROMOSYON	COCA COLA 2.5	39	120	192
:											
:											
2010	5	4	Salı	ILKBAHAR					63	26	72
2010	5	5	Çrş	ILKBAHAR					39	25	87
2010	5	6	Perş	ILKBAHAR					42	24	86
2010	5	7	Cuma	ILKBAHAR					79	38	122
2010	5	8	Cts	ILKBAHAR					80	36	224

Y	M	D	GÜN	MEVSİM	ÖZEL GÜNLER	COCA-COLA 1 LİTRE PROMOSYON	PEPSİ COLA 2.5 LT PROMOSYON	COCA-COLA 2.5 L PROMOSYON	COCA-COLA 1 LİTRE Satış miktarı	PEPSİ COLA 2.5 LT Satış miktarı	COCA-COLA 2.5 L Satış miktarı
2010	5	9	Pzr	ILKBAHAR					40	49	193
2010	5	10	Pts	ILKBAHAR					36	23	89
2010	5	11	Salı	ILKBAHAR					26	32	60
2010	5	12	Çrş	ILKBAHAR					33	28	74
2011	12	31	Cts	KIS	YILBASI				25	25	
2010	5	15	Pzr	ILKBAHAR					25	25	
2010	5	16	Pts	ILKBAHAR				COCA COLA 2.5 L PROMOSYON	20	20	
2010	31	12	Cts	KIS	YILBASI				25	25	
2010	15	5	Pzr	ILKBAHAR					25	25	
2010	16	5	Pts	ILKBAHAR				COCA COLA 2.5 L PROMOSYON	20	20	
2010	17	7	Cts	YAZ				COCA COLA 2.5 L PROMOSYON	25	25	
2010	20	7	Pzr	YAZ				COCA COLA 2.5 L PROMOSYON	25	25	
2010	18	8	Pzr	YAZ				COCA COLA 2.5 L PROMOSYON	25	25	
2010	11	8	Çrş	YAZ			PEPSİ PROMOSYON		30	20	

EK 2

[illegible]

Cognitive Skills	Memory																		Attention																		Emotional Stability																		Social Interaction																		Physical Health																		Academic Performance																		Personal Development																		Career Progression																		Life Satisfaction																		Overall Well-being																																																					
	Short-term																		Long-term																		Stress Management																		Communication																		Endurance																		Knowledge																		Growth																		Advancement																		Quality																		Quality																		Quality																		Quality																	
	Recall																		Focus																		Coping																		Networking																		Strength																		Performance																		Development																		Progression																		Satisfaction																		Satisfaction																		Satisfaction																		Satisfaction																	
	Verbal																		Visual																		Cognitive																		Interpersonal																		Cardio																		Cognitive																		Personal																		Professional																		Personal																		Professional																		Personal																		Professional																	
	Reading																		Listening																		Thinking																		Feeling																		Moving																		Learning																		Living																		Working																		Living																		Working																		Living																		Working																	
	Comprehension																		Retention																		Problem Solving																		Empathy																		Endurance																		Knowledge																		Growth																		Advancement																		Quality																		Quality																		Quality																		Quality																	
	Understanding																		Remembering																		Reasoning																		Relationships																		Vitality																		Performance																		Development																		Progression																		Satisfaction																		Satisfaction																		Satisfaction																		Satisfaction																	
	Analysis																		Organization																		Self-control																		Cooperation																		Stamina																		Efficiency																		Improvement																		Growth																		Growth																		Growth																		Growth																																			
	Critical Thinking																		Detail Orientation																		Resilience																		Teamwork																		Flexibility																		Productivity																		Innovation																		Innovation																		Innovation																		Innovation																																																					
	Problem Solving																		Time Management																		Stress Management																		Communication																		Endurance																		Academic Achievement																		Personal Growth																		Career Advancement																		Life Quality																		Overall Health																																																					
Emotional Stability	Decision Making																		Focus																		Emotion Regulation																		Social Skills																		Physical Fitness																		Academic Achievement																		Personal Growth																		Career Advancement																		Life Quality																		Overall Health																																																					
	Planning																		Attention																		Stress Management																		Communication																		Endurance																		Academic Achievement																		Personal Growth																		Career Advancement																		Life Quality																		Overall Health																																																					
	Goal Setting																		Focus																		Stress Management																		Communication																		Endurance																		Academic Achievement																		Personal Growth																		Career Advancement																		Life Quality																		Overall Health																																																					
	Time Management																		Focus																		Stress Management																		Communication																		Endurance																		Academic Achievement																		Personal Growth																		Career Advancement																		Life Quality																		Overall Health																																																					
	Goal Setting																		Focus																		Stress Management																		Communication																		Endurance																		Academic Achievement																		Personal Growth																		Career Advancement																		Life Quality																		Overall Health																																																					
	Time Management																		Focus																		Stress Management																		Communication																		Endurance																		Academic Achievement																		Personal Growth																		Career Advancement																		Life Quality																		Overall Health																																																					
	Goal Setting																		Focus																		Stress Management																		Communication																		Endurance																		Academic Achievement																		Personal Growth																		Career Advancement																		Life Quality																		Overall Health																																																					
	Time Management																		Focus																		Stress Management																		Communication																		Endurance																		Academic Achievement																		Personal Growth																		Career Advancement																		Life Quality																		Overall Health																																																					
	Goal Setting																		Focus																		Stress Management																		Communication																		Endurance																		Academic Achievement																		Personal Growth																		Career Advancement																		Life Quality																		Overall Health																																																					
	Time Management																		Focus																		Stress Management																		Communication																		Endurance																		Academic Achievement																		Personal Growth																		Career Advancement																		Life Quality																		Overall Health																																																					
Social Interaction	Memory																		Attention																		Emotional Stability																		Social Interaction																		Physical Health																		Academic Performance																		Personal Development																		Career Progression																		Life Satisfaction																		Overall Well-being																																																					
	Short-term																		Long-term																		Stress Management																		Communication																		Endurance																		Knowledge																		Growth																		Advancement																		Quality																		Quality																		Quality																		Quality																	
	Recall																		Focus																		Coping																		Networking																		Strength																		Performance																		Development																		Progression																		Satisfaction																		Satisfaction																		Satisfaction																		Satisfaction																	
	Verbal																		Visual																		Cognitive																		Interpersonal																		Cardio																		Cognitive																		Personal																		Professional																		Personal																		Professional																		Personal																		Professional																	
	Reading																		Listening																		Thinking																		Feeling																		Moving																		Learning																		Living																		Working																		Living																		Working																		Living																		Working																	
	Comprehension																		Retention																		Problem Solving																		Empathy																		Endurance																		Knowledge																		Growth																		Advancement																		Quality																		Quality																		Quality																		Quality																	
	Understanding																		Remembering																		Reasoning																		Relationships																		Vitality																		Performance																		Development																		Progression																		Satisfaction																		Satisfaction																		Satisfaction																		Satisfaction																	
	Analysis																		Organization																		Self-control																		Cooperation																		Stamina																		Efficiency																		Improvement																		Growth																		Growth																		Growth																		Growth																																			
	Critical Thinking																		Detail Orientation																		Resilience																		Teamwork																		Flexibility																		Productivity																		Innovation																		Innovation																		Innovation																		Innovation																																																					
	Problem Solving																		Time Management																		Stress Management																		Communication																		Endurance																		Academic Achievement																		Personal Growth																		Career Advancement																		Life Quality																		Overall Health																																																					
Physical Health	Decision Making																		Focus																		Emotion Regulation																		Social Skills																		Physical Fitness																		Academic Achievement																		Personal Growth																		Career Advancement																		Life Quality																		Overall Health																																																					
	Planning																		Attention																		Stress Management																		Communication																		Endurance																		Academic Achievement																		Personal Growth																		Career Advancement																		Life Quality																		Overall Health																																																					
	Goal Setting																		Focus																		Stress Management																		Communication																		Endurance																		Academic Achievement																		Personal Growth																		Career Advancement																		Life Quality																		Overall Health																																																					
	Time Management																		Focus																		Stress Management																		Communication																		Endurance																		Academic Achievement																		Personal Growth																		Career Advancement																		Life Quality																		Overall Health																																																					
	Goal Setting																		Focus																		Stress Management																		Communication																		Endurance																		Academic Achievement																		Personal Growth																		Career Advancement																		Life Quality																		Overall Health																																																					
	Time Management																		Focus																		Stress Management																		Communication																		Endurance																		Academic Achievement																		Personal Growth																		Career Advancement																		Life Quality																		Overall Health																																																					
	Goal Setting																		Focus																		Stress Management																		Communication																		Endurance																		Academic Achievement																		Personal Growth																		Career Advancement																		Life Quality																		Overall Health																																																					
	Time Management																		Focus																		Stress Management																		Communication																		Endurance																		Academic Achievement																		Personal Growth																		Career Advancement																		Life Quality																		Overall Health																																																					
	Goal Setting																		Focus																		Stress Management																		Communication																		Endurance																		Academic Achievement																		Personal Growth																		Career Advancement																		Life Quality																		Overall Health																																																					
	Time Management																		Focus																		Stress Management																		Communication																		Endurance																		Academic Achievement																		Personal Growth																		Career Advancement																		Life Quality																		Overall Health																																																					
Academic Performance	Memory																		Attention																		Emotional Stability																		Social Interaction																		Physical Health																		Academic Performance																		Personal Development																		Career Progression																		Life Satisfaction																		Overall Well-being																																																					
	Short-term																		Long-term																		Stress Management																		Communication																		Endurance																		Knowledge																		Growth																		Advancement																		Quality																		Quality																		Quality																		Quality																	
	Recall																		Focus																		Coping																		Networking																		Strength																		Performance																		Development																		Progression																		Satisfaction																		Satisfaction																		Satisfaction																		Satisfaction																	
	Verbal																		Visual																		Cognitive																		Interpersonal																		Cardio																		Cognitive																		Personal																		Professional																		Personal																		Professional																		Personal																		Professional																	
	Reading																		Listening																		Thinking																		Feeling																		Moving																		Learning																		Living																		Working																		Living																		Working																		Living																		Working																	
	Comprehension																		Retention																		Problem Solving																		Empathy																		Endurance																		Knowledge																		Growth																		Advancement																		Quality																		Quality																		Quality																		Quality																	
	Understanding																		Remembering																		Reasoning																		Relationships																		Vitality																		Performance																		Development																		Progression																		Satisfaction																		Satisfaction																		Satisfaction																		Satisfaction																	
	Analysis																		Organization																		Self-control																		Cooperation																		Stamina																		Efficiency																		Improvement																		Growth																		Growth																		Growth																		Growth																																			
	Critical Thinking																		Detail Orientation																		Resilience																		Teamwork																		Flexibility																		Productivity																		Innovation																		Innovation																		Innovation																		Innovation																																																					
	Problem Solving																		Time Management																		Stress Management																		Communication																		Endurance																		Academic Achievement																		Personal Growth																		Career Advancement																		Life Quality																		Overall Health																																																					
Personal Development	Decision Making																		Focus																		Emotion Regulation																		Social Skills																		Physical Fitness																		Academic Achievement																		Personal Growth																		Career Advancement																		Life Quality																		Overall Health																																																					
	Planning																		Attention																		Stress Management																		Communication																		Endurance																		Academic Achievement																		Personal Growth																		Career Advancement																		Life Quality																		Overall Health																																																					
	Goal Setting																		Focus																		Stress Management																		Communication																		Endurance																		Academic Achievement																		Personal Growth																		Career Advancement																		Life Quality																		Overall Health																																																					
	Time Management																		Focus																		Stress Management																		Communication																		Endurance																		Academic Achievement																		Personal Growth																		Career Advancement																		Life Quality																		Overall Health																																																					
	Goal Setting																		Focus																		Stress Management																		Communication																		Endurance																		Academic Achievement																		Personal Growth																		Career Advancement																		Life Quality																		Overall Health																																																					
	Time Management																		Focus																		Stress Management																		Communication																		Endurance																		Academic Achievement																		Personal Growth																		Career Advancement																		Life Quality																		Overall Health																																																					
	Goal Setting																		Focus																		Stress Management																		Communication																		Endurance																		Academic Achievement																		Personal Growth																		Career Advancement																		Life Quality																		Overall Health																																																					
	Time Management																		Focus																		Stress Management																		Communication																		Endurance																		Academic Achievement																		Personal Growth																		Career Advancement																		Life Quality																		Overall Health																																																					
	Goal Setting																		Focus																		Stress Management																		Communication																		Endurance																		Academic Achievement																		Personal Growth																		Career Advancement																		Life Quality																		Overall Health																																																					
	Time Management																		Focus																		Stress Management																		Communication																		Endurance																		Academic Achievement																		Personal Growth																		Career Advancement																		Life Quality																		Overall Health																																																					
Career Progression	Memory																		Attention																		Emotional Stability																		Social Interaction																		Physical Health																		Academic Performance																		Personal Development																		Career Progression																		Life Satisfaction																		Overall Well-being																																																					
	Short-term																		Long-term																		Stress Management																		Communication																		Endurance																		Knowledge																		Growth																		Advancement																		Quality																		Quality																		Quality																		Quality																	
	Recall																		Focus																		Coping																		Networking																		Strength																		Performance																		Development																		Progression																		Satisfaction																		Satisfaction																		Satisfaction																		Satisfaction																	
	Verbal																		Visual																		Cognitive																		Interpersonal																		Cardio																		Cognitive																		Personal																		Professional																		Personal																		Professional																		Personal																		Professional																	
	Reading																		Listening																		Thinking																		Feeling																		Moving																		Learning																		Living																		Working																		Living																		Working																		Living																		Working																	
	Comprehension																		Retention																		Problem Solving																		Empathy																		Endurance																		Knowledge																		Growth																		Advancement																		Quality																		Quality																		Quality																		Quality																	
	Understanding																		Remembering																		Reasoning																		Relationships																		Vitality																		Performance																		Development																		Progression																		Satisfaction																		Satisfaction																		Satisfaction																		Satisfaction																	
	Analysis																		Organization																		Self-control																		Cooperation																		Stamina																		Efficiency																		Improvement																		Growth																		Growth																		Growth																		Growth																																			
	Critical Thinking																		Detail Orientation																		Resilience																		Teamwork																		Flexibility																		Productivity																		Innovation																		Innovation																		Innovation																		Innovation																																																					
	Problem Solving																		Time Management																		Stress Management																		Communication																		Endurance																		Academic Achievement																		Personal Growth																		Career Advancement																		Life Quality																		Overall Health																																																					
Life Satisfaction	Decision Making																		Focus																		Emotion Regulation																		Social Skills																		Physical Fitness																		Academic Achievement																		Personal Growth																		Career Advancement																		Life Quality																		Overall Health																																																					
	Planning																		Attention																		Stress Management																		Communication																		Endurance																		Academic Achievement																		Personal Growth																		Career Advancement																		Life Quality																		Overall Health																																																					
	Goal Setting																		Focus																		Stress Management																		Communication																		Endurance																		Academic Achievement																		Personal Growth																		Career Advancement																		Life Quality																		Overall Health																																																					
	Time Management																		Focus																		Stress Management																		Communication																		Endurance																		Academic Achievement																		Personal Growth																		Career Advancement																		Life Quality																		Overall Health																																																					
	Goal Setting																		Focus																		Stress Management																		Communication																		Endurance																		Academic Achievement																		Personal Growth																		Career Advancement																		Life Quality																		Overall Health																																																					
	Time Management																		Focus																		Stress Management																		Communication																		Endurance																		Academic Achievement																		Personal Growth																		Career Advancement																		Life Quality																		Overall Health																																																					
	Goal Setting																		Focus																		Stress Management																		Communication																		Endurance																		Academic Achievement																		Personal Growth																		Career Advancement																		Life Quality																		Overall Health																																																					
	Time Management																		Focus																		Stress Management																		Communication																		Endurance																		Academic Achievement																		Personal Growth																		Career Advancement																		Life Quality																		Overall Health																																																					
	Goal Setting																		Focus																		Stress Management																		Communication																		Endurance																		Academic Achievement																		Personal Growth																		Career Advancement																		Life Quality																		Overall Health																																																					
	Time Management																		Focus																		Stress Management																		Communication																		Endurance																		Academic Achievement																		Personal Growth																		Career Advancement																		Life Quality																		Overall Health																																																					
Overall Well-being	Memory																		Attention																		Emotional Stability																		Social Interaction																		Physical Health																		Academic Performance																		Personal Development																		Career Progression																		Life Satisfaction																		Overall Well-being																																																					
	Short-term																		Long-term																		Stress Management																		Communication																		Endurance																		Knowledge																		Growth																		Advancement																		Quality																		Quality																		Quality																		Quality																	
	Recall																		Focus																		Coping																		Networking																		Strength																		Performance																		Development																		Progression																		Satisfaction																		Satisfaction																		Satisfaction																		Satisfaction																	
	Verbal																		Visual																		Cognitive																		Interpersonal																		Cardio																		Cognitive																		Personal																		Professional																		Personal																		Professional																		Personal																		Professional																	
	Reading																		Listening																		Thinking																		Feeling																		Moving																		Learning																		Living																		Working																		Living																		Working																		Living																		Working																	
	Comprehension																		Retention																		Problem Solving																		Empathy																		Endurance																		Knowledge																		Growth																		Advancement																		Quality																		Quality																		Quality																		Quality																	
	Understanding																		Remembering																		Reasoning																		Relationships																		Vitality																		Performance																		Development																		Progression																		Satisfaction																		Satisfaction																		Satisfaction																		Satisfaction																	
	Analysis																		Organization																		Self-control																		Cooperation																		Stamina																		Efficiency																		Improvement																		Growth																		Growth																		Growth																		Growth																																			
	Critical Thinking																		Detail Orientation																		Resilience																		Teamwork																		Flexibility																		Productivity																		Innovation																		Innovation																		Innovation																		Innovation																																																					
	Problem Solving																		Time Management																		Stress Management																		Communication																		Endurance																		Academic Achievement																		Personal Growth																		Career Advancement																		Life Quality																		Overall Health																																																					
74	103	106	127	208	210	80	68	94	111	116	255	263	139	110	110	95	82	128																																																																																																																																																																																																						
39	24	36	23	64	48	52	38	42	55	59	63	94	41	46	46	60	194	136																																																																																																																																																																																																						
19	12	20	23	54	52	33	30	30	2	20	20	13	5	29	56	40	43	35																																																																																																																																																																																																						

[illegible]

[illegible]

ÖZGEÇMİŞ

Doğum tarihi	14.03.1986	
Doğum yeri	Aydın	
Lise	1996-2004	Muğla Anadolu Lisesi
Lisans	2004-2008	Yıldız Teknik Üniversitesi Kimya-Metalurji Fakültesi Matematik Mühendisliği Bölümü
Yüksek Lisans	2008-2011	Yıldız Teknik Üniversitesi Fen Bilimleri Enstitüsü Endüstri Müh. Ana Bilim Dalı, End. Müh. Programı
Çalıştığı Kurum	2010- ...	MİGROS Ticaret A.Ş